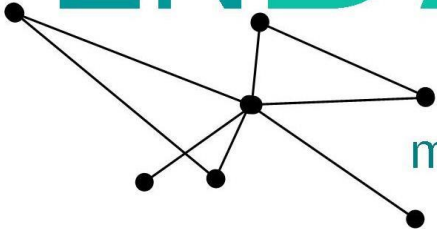


OPENDATA meets KI



Stephanie von Riegen, Bernd Neumann,
Yen Dieu Pham, Lothar Hotz, Santosh Basavaraju

Hamburger Informatik Technologie-Center e.V.

Fachbereich Informatik, Universität Hamburg, Vogt-Kölln-Str. 30, D-22527 Hamburg
Kontakt: info@hitec-hamburg.de



ZUSAMMENFASSUNG

Im Projekt ODAKI wurden die Möglichkeiten und Vorteile von Methoden der Künstlichen Intelligenz bei der Entwicklung innovativer Open Data-Anwendungen im Mobilitätsbereich untersucht und in unterschiedlichen Projektskizzen aufgezeigt.

INHALTSVERZEICHNIS

ZUSAMMENFASSUNG	2
INHALTSVERZEICHNIS	3
1. EINLEITUNG	5
2. PROJEKTRAHMEN	7
2.1. PROJEKT BETEILIGTE	8
2.2. ZIELE	9
2.2.1. <i>Arbeitspakete</i>	9
2.2.2. <i>Bezug des Vorhabens zu förderpolitischen Zielen</i>	9
3. KI-METHODEN	11
3.1. KI-METHODEN EINFÜHRUNG	12
3.2. KI-METHODEN ZUR DATENREPRÄSENTATION	13
3.2.1. <i>OWL</i>	14
3.2.2. <i>Linked Open Data</i>	15
3.2.3. <i>Knowledge Graphs</i>	16
3.2.4. <i>Regelbasierte Systeme</i>	16
3.2.5. <i>Deduktive Datenbanken</i>	16
3.2.6. <i>Ontologieabgleich</i>	17
3.3. KI-METHODEN ZUR DATENANALYSE UND -AUFBEREITUNG	18
3.3.1. <i>Suchverfahren</i>	18
3.3.2. <i>Lernverfahren</i>	19
3.3.3. <i>Fallbasiertes Schließen</i>	21
3.3.4. <i>Empfehlungsdienste</i>	21
3.3.5. <i>Bayes Netze</i>	22
3.3.6. <i>Planen</i>	23
3.4. BILDVERARBEITUNG	24
3.4.1. <i>Objekterkennung</i>	24
3.4.2. <i>Szenenanalyse</i>	24
3.4.3. <i>Inhaltsbasierter Bildabruf</i>	25
3.5. SPRACHTECHNOLOGIE	26
3.6. ROBOTIK	27
3.7. ABSCHLIEßENDE BEWERTUNG	28
3.8. KI-SOFTWARE-WERKZEUGE	29
4. INTERVIEWS UND TAGUNGEN	33
4.1. INTERVIEWS MIT STAKEHOLDERN	34

4.2.	TAGUNGEN UND WORKSHOPS	35
5.	PROJEKTSKIZZEN	37
5.1.	TRAFFIC ALERT	38
5.2.	BIKE DISTRIBUTOR	41
5.3.	HISTOURY	44
5.4.	3D STREET MATCH	46
5.5.	CITY VISION.....	49
5.6.	PERSON STREAM.....	51
5.7.	MY WAY	53
5.8.	SMART MAINTENANCE	55
5.9.	REPORT ANALYSIS	57
6.	ERFAHRUNGEN UND AUSBLICK	59
6.1.	NUTZEN VON KI-VERFAHREN.....	60
6.2.	HERAUSFORDERUNGEN BEI DER ANWENDUNG VON DEEP LEARNING.....	61
6.3.	EMPFEHLUNGEN ZUR DURCHFÜHRUNG VON KI-PROJEKTEN	62
6.4.	VERTEILTE ROLLEN IN KI-PROJEKTEN.....	63
6.5.	ABSCHLUSS-WORKSHOP	64
7.	QUELLENANGABEN	65
7.1.	DATENVERZEICHNISSE	66
7.2.	LITERATURVERZEICHNIS	72
7.3.	KI-BIBLIOTHEKEN.....	74

1. EINLEITUNG

Welche Bedeutung haben Verfahren der Künstlichen Intelligenz (KI) bei der innovativen Verarbeitung von Open Data aus dem Mobilitätsbereich? Dies ist die Kernfrage, die ein Projektteam des Hamburger Informatik Technologie-Center (HITeC) in Zusammenarbeit mit der Geschäfts- und Koordinierungsstelle GovData (GKSt) im Rahmen des Projektes ODAKI ("Open Data Innovationen mit KI-Methoden") untersucht hat. Das Projekt ist Teil der Maßnahme mFund des Bundesministeriums für Verkehr und digitale Infrastruktur (BMVI), mit der Geschäftsideen zur Auswertung digitaler Mobilitätsdaten gefördert werden, z.B. intelligente Reiseplaner oder adaptive Verkehrsleitsysteme.

Dass KI dabei eine bedeutende Rolle spielen kann, liegt aus verschiedenen Gründen nahe.

- KI umfasst einen etablierten Methodenschatz zur Entwicklung intelligenter Systeme, darunter auch die derzeit viel beachteten KI-Lernverfahren.
- KI hat sich als eine der Schlüsseltechnologien für Industrie 4.0 erwiesen, etwa in den Bereichen Robotik, adaptive Planung und bei der Verarbeitung von Big Data.
- Die intelligente Verarbeitung von Mobilitätsdaten im Zusammenhang mit anderen heterogenen Datenquellen (z.B. Wetterdaten, statistischen Informationen) stellt Anforderungen, für die KI-Methoden grundsätzliche Eignung haben.

Das Projekt ODAKI (Laufzeit 8/17 - 3/18) hatte zum Ziel, das Potenzial der KI für ein breites Spektrum möglicher Anwendungen im Mobilitätsbereich zu untersuchen. Dazu wurden Datenquellen und ihre Verfügbarkeit als Open Data geprüft, Stakeholder in Unternehmen und öffentlichen Einrichtungen befragt, bisherige Anwendungen im mFund-Rahmen gesichtet, sowie - last not least - innovative Beispielanwendungen konzipiert und in Gestalt von zwei prototypischen Entwicklungen auch demonstrierbar gemacht.

Der vorliegende Abschlussbericht legt Rechenschaft über die in ODAKI geleistete Arbeit ab. Er wendet sich aber ebenso an IT-Fachleute, Unternehmer und Startups, die an der Entwicklung innovativer Systeme interessiert sind. Es ist zu hoffen, dass die aufgezeigten Möglichkeiten, aber auch die erkennbaren Hindernisse, zu vermehrten und erfolgreichen Anwendungsentwicklungen beitragen werden.

Abschnitt 2 informiert über den Projektplan. Die Projektbeteiligten werden vorgestellt, und die Projektziele werden erläutert.

Abschnitt 3 gibt einen Überblick über den für das Projekt relevanten KI-Methodenschatz. Die Lektüre kann von KI-Fachleuten gerne übersprungen werden.

Abschnitt 4 berichtet über Interviews mit Stakeholdern. Die Gespräche haben sehr zum besseren Verständnis der zur Verfügung stehenden Datenquellen, sowie wünschenswerter und realistischer Anwendungen beigetragen.

Abschnitt 5 ist der Hauptteil des Berichtes. Hier werden Projektskizzen für mögliche KI-Anwendungen im Mobilitätsbereich, gruppiert in Themenfelder, detailliert präsentiert.

In Abschnitt 6 werden zum Abschluss die wichtigsten Erkenntnisse zusammengestellt, die bei den Untersuchungen von ODAKI gewonnen wurden und für zukünftige Entwicklungen von Bedeutung sind.

Quellenangaben finden sich in Abschnitt 7.

2. PROJEKTRAHMEN

2.1. PROJEKTBETEILIGTE

Hamburger Informatik Technologietransfer-Center (HITeC)

HITeC ist das Forschungs- und Technologietransferzentrum des Fachbereichs Informatik der Universität Hamburg. Aufgrund seines unabhängigen Status bietet HITeC flexible und professionelle Kooperationsmöglichkeiten. HITeC-Lösungen basieren auf neuesten Forschungsergebnissen und verschaffen Vorteile durch überlegene Technologien. HITeC ist ein eingetragener, gemeinnütziger Verein, der von Mitgliedern des Fachbereichs Informatik der Universität Hamburg getragen wird. Der Verein ist über einen Kooperationsvertrag mit der Universität Hamburg verbunden. Für das vorliegende Projekt sind neben den oben genannten Erfahrungen im Bereich KI die besonderen Referenzen zu Arbeiten mit großen Datenmengen in Verbindung mit KI-Methoden zu nennen [Hotz et al., 2008] als auch die Entwicklung des Transparenzportals Hamburg¹, welche durch HITeC durchgeführt wurde. Das Transparenzportal Hamburg hat das Open Data-Portal der Stadt abgelöst und erlaubt den Zugriff auf aktuell ca. 60.000 Datensätze und Dokumente. Ein ähnliches Portal, welches mehrere Datenquellen zusammenführt und durch HITeC, in diesem Fall in Zusammenarbeit mit der Staats- und Universitätsbibliothek Hamburg, entwickelt wurde, ist HamburgWissenDigital².

HITeC bearbeitete die technologischen Aspekte des Projektes, insbesondere die Rolle von KI-Methoden. Dazu gehörte insbesondere die Entwicklung mehrerer Demonstratoren. HITeC war federführend bei der Ausfertigung von Ergebnisberichten.

Projektteam der Geschäfts- und Koordinierungsstelle GovData (GKSt)

Hamburg ist Sitz der Geschäfts- und Koordinierungsstelle GovData (im Folgenden GKSt). Die GKSt ist in der Finanzbehörde, Abteilung für E-Government und IT-Steuerung, angesiedelt. Bei „GovData“ handelt es sich um das Open Data-Portal des Bundes und der Länder. In diesem Portal werden Datensätze aus der Verwaltung für die Öffentlichkeit zur Verfügung gestellt. Jedem/jeder Bürger/in stehen sie kostenlos und zur freien Weiterverwendung zur Verfügung. Unter www.GovData.de sind die Daten aus allen großen Open Data-Portalen der Bundesrepublik Deutschland zu finden.

GovData ist Teil der europäischen Portale. Die Daten aus dem GovData Portal sind dementsprechend auch im Open Data Portal der EU abrufbar. GovData ist eine Anwendung des IT-Planungsrates und wird auf Basis einer Verwaltungsvereinbarung durch den Bund und einen Teil der Bundesländer finanziert.

Die GKSt übernahm die Stakeholder-Analyse für die Ermittlung potentieller Quellen von Mobilitätsdaten sowie eine Bewertung der Machbarkeit und des gesellschaftlichen Nutzens der skizzierten Anwendungen.

¹ <http://transparenzportal.hamburg.de>

² <http://hamburgwissen-digital.de>

2.2. ZIELE

2.2.1. ARBEITSPAKETE

Das Projekt war in fünf Arbeitspakete gegliedert:

1. Untersuchung der zur Verfügung stehenden Datenquellen

Hierfür wurden Datenquellen des BMVI/mFund, Open Data-Portale und andere Datenbestände auf Breite, räumlich-zeitliche Dichte, sowie verwendete Datenstrukturen untersucht.

2. Darstellung der für Anwendungen relevanten KI-Methoden

Die Darstellung befindet sich als Abschnitt 3 in diesem Bericht. Als besonders relevant sind KI-Methoden zur strukturierten Datenrepräsentation sowie zur Datenanalyse und Datenaufbereitung anzusehen.

3. Identifikation und Beschreibung möglicher Anwendungen

Dies ist der Hauptteil des Projektes. Die Ergebnisse, zusammengefasst nach Themenbereichen, werden in Abschnitt 5 präsentiert.

4. Detaillierte Präsentation einer ausgewählten Anwendung

Es wurden drei Anwendungen in Vorstudien entwickelt und mit konkreten Daten demonstrierbar gemacht. Eine Anwendung konnte als Prototyp realisiert werden.

5. Verbreitung der Projektergebnisse

Die Projektergebnisse wurden am 23.3.2018 in einem Abschluss-Workshop präsentiert. Der vorliegende Bericht wird an alle Interviewpartner und interessierte wissenschaftlichen Kontakte von HITeC verteilt, sowie über die Internetseiten von ODAKI unter <http://odaki.informatik.uni-hamburg.de/abschlussbericht/> veröffentlicht.

2.2.2. BEZUG DES VORHABENS ZU FÖRDERPOLITISCHEN ZIELEN

Das Vorhaben trägt wegen seiner zugrundeliegenden Thematik zu mehreren förderpolitischen Zielen bei.

Durch die Identifizierung relevanter KI-Methoden sowohl für vernetzbare Datenrepräsentation als auch zur Verarbeitung mit fortgeschrittenen Verfahren wird der Boden für vielfältige innovative Anwendungen von Verkehrsdaten bereitet. Gerade KI-Methoden besitzen durch ihre vielfältigen Möglichkeiten zur Analyse und Zusammenführung großer heterogener Datenmengen viel Potenzial bei der Generierung von „Smart Data“ aus „Big Data“ und damit zur Veredelung der bereitstehenden Mobilitätsdaten.

Im Sinne des Open Data-Ansatzes wird dabei allen interessierten Akteuren der Zugang zu den resultierenden Anwendungsskizzen und damit zu neuen innovativen Zugangsmethoden und ggf. Geschäftsmodellen eröffnet.

Konkret sind die Projektziele darauf angelegt, mehrere (ca. 20) Datenquellen aus Quellen des BMVI sowie anderen Open Data-Portalen mittels intelligenter Verfahren zu untersuchen. Dabei werden Anwendungsmöglichkeiten entwickelt, die diese Daten in Verbindung mit KI-Methoden auswerten. Es werden bestehende Datenquellen erhoben, und eine breite Nutzung und intelligente Vernetzung der Daten in innovativen und fortschrittlichen Anwendungen³ wird dargestellt.

Durch gezielte Stakeholder-Befragungen bei Datenlieferanten, Behörden, Anwendern und Software-Firmen werden konkrete Anforderungen (z.B. Erhöhung der Nutzbarmachung von Daten durch ihre Verlinkung, mobile Anwendungen) für die Entwicklung der Anwendungsskizzen herangezogen. So werden *externe Akteure* eingebunden. Durch die konkreten Anwendungsskizzen und auch den zu erstellenden Demonstrator werden *innovative Lösungsansätze* beschrieben, sowie *ökonomische und gesellschaftliche Potenziale für eine moderne Anwendung* aufgezeigt. Damit trägt das Projekt dazu bei, *tägliche Mobilitätsszenarien in Deutschland wirtschaftlicher, komfortabler, sicherer und umweltfreundlicher zu machen*.

In diesem Zusammenhang werden weitere Datenbedarfe identifiziert, die durch die Bereitstellung entsprechender offener Verwaltungsdaten zukünftig gedeckt werden könnten.

Durch die Bearbeitung konkreter Anwendungen im Zuge des Projekts wird aufgezeigt, auf welche Weise Datenquellen durch KI-Methoden analysiert werden können. Dadurch kann ein *systematisches Vorgehen* bei der Entwicklung zukünftiger Anwendungen etabliert werden.

Das Projekt nimmt direkten Bezug auf das Themenfeld „Datenbasierte Anwendungen“ und trägt durch die Einbeziehung von Clustering- und Lernverfahren der KI zur effizienten Analyse von "Big Data" bei.

³ Zitate aus [BMVI 2016] sind *kursiv*.

3. KI-METHODEN

3.1. KI-METHODEN EINFÜHRUNG

In diesem Bericht wird dargestellt, welche KI-Methoden bei der Auswertung und Verarbeitung von Open Data beim Entwickeln von innovativen Anwendungen zum Einsatz kommen können und Vorteile gegenüber klassischer Datenverarbeitung bieten. Der Bericht wendet sich an IT-Fachleute, die sich über den Stand von KI-Technologien insbesondere im Hinblick auf Open Data im Mobilitätsbereich informieren wollen. Dabei wird das Ziel verfolgt, alle hierfür relevanten Teilgebiete der KI anzusprechen, nicht nur die derzeit oft als "die KI" missverstandenen Lernverfahren auf der Basis von Künstlichen Neuronalen Netzen (KNN).

Eine genaue Abgrenzung zwischen KI und klassischer IT-Technologie ist nicht immer möglich. Ein Hauptgrund dafür ist die zunehmende Integration von KI-Methoden in komplexe Software-Systeme, in denen Verfahren unterschiedlicher Provenienz verbunden und an konkrete Anwendungsziele angepasst werden. In diesen Systemen gibt es keine klare Grenze, an der KI "anfängt".

Ein weiterer Grund für die unscharfe Trennung von KI und klassischer Datenverarbeitung ist die Verarbeitung von Big Data, also von sehr großen Datenmengen. Hier müssen aufwändige KI-Methoden oft zugunsten von hocheffizienten klassischen Methoden "abgespeckt" werden, z.B. bei der Realisierung semantischer Datenrepräsentationen. Big Data werden zunehmend bei der Weiterentwicklung von KI-Methoden berücksichtigt.

Darüber hinaus hat die Entwicklung des Semantic Web zu einer breiten Palette von Datenstrukturen und Techniken geführt (z.B. Linked Open Data, Knowledge Graphs), die in ihrer allgegenwärtigen Rolle bei Google und anderen Diensten nicht als KI-Methoden wahrgenommen werden, auch wenn sie aus der KI entstanden sind.

Die Darstellung von KI-Methoden kann in diesem Bericht natürlich nicht mit allen Details und Varianten erfolgen - das Fachgebiet hat einen beträchtlichen Umfang, wie die Curricula an einschlägigen Universitäten und die zur Verfügung stehenden Fachbücher zeigen. Hervorzuheben ist das Buch "Artificial Intelligence - A Modern Approach" [Russell & Norvig 2010], das in seiner dritten Auflage mehr als 1100 Seiten umfasst, eine vierte, erweiterte Auflage ist in Arbeit.

Der Bericht stützt sich neben Fachbüchern auch auf die neuesten wissenschaftlichen Ergebnisse, über die auf internationalen Konferenzen berichtet wurde. Auf der im August 2017 in Melbourne stattgefundenen International Joint Conference on Artificial Intelligence [IJCAI-2017] wurden beispielsweise mehr als 240 Beiträge präsentiert. Der IJCAI voraus ging der Big Data Summit 2017 [BDS 2017], auf dem die enge Verbindung von Big Data und KI deutlich wurde.

Ebenfalls informativ war der Big-Data.AI Summit (28.2 - 1.3.18 in Hanau), bei dem innovative Anwendungen und wirtschaftlicher Nutzen im Vordergrund standen.

Die folgenden Abschnitte behandeln KI-Methoden zur Datenrepräsentation (Abschnitt 3.2), KI-Methoden zur Datenanalyse und Datenaufbereitung (Abschnitt 3.3), Verfahren zur Bild- und Sprachanalyse (Abschnitte 3.4 und 3.5), zur Robotik (Abschnitt 3.6), und gibt schließlich eine zusammenfassende Bewertung des KI-Anwendungspotenzials in Abschnitt 3.7. Im Anhang (Abschnitt 3.8) werden erprobte Werkzeuge zur Systementwicklung mithilfe von KI-Methoden aufgeführt.

3.2. KI-METHODEN ZUR DATENREPRÄSENTATION

In der KI sind die zentralen Ziele der Datenrepräsentation (i) Bedeutungsbeschreibung und (ii) Ermöglichen von Schlussfolgerungen (Inferenzen). Beide Aspekte sind für Open Data hochrelevant, wie im Folgenden kurz ausgeführt wird.

Open Data, so auch die für dieses Vorhaben wichtigen Daten im Mobilitätsportal mCloud, enthalten meist heterogene Datenbestände, die in unterschiedlichen Datenverarbeitungskulturen entstanden sind. Infolgedessen unterliegen den Daten häufig unterschiedliche Begriffswelten, Bezeichnungen stimmen selbst bei identischen Bedeutungen selten von vornherein überein. Offenbar sind hier Methoden und Werkzeuge erforderlich, mit denen Bedeutungskonzepte einheitlich definiert und aufeinander abgebildet werden können.

Das Ermöglichen von Schlussfolgerungen ist eng mit einer logisch fundierten Bedeutungsrepräsentation verbunden und seit Anbeginn eine klassische Domäne der KI. Schlussfolgerungen erlauben es, nicht offensichtliche Konsequenzen von Bedeutungskonzepten und konkreten Datenbeständen mit garantiert korrekten Rechnerverfahren abzuleiten. Dadurch können z.B. widersprüchliche Daten erkannt oder zusätzliche Eigenschaften explizit gemacht werden. Diese Möglichkeiten sind gerade bei Big Data von prominenter Bedeutung.

Die KI bietet ein umfangreiches Methodenrepertoire für Wissensrepräsentation und darauf basierende Inferenzmethoden. Umfassende Darstellungen finden sich in [Harmelen et al. 2008] und [Russell & Norvig 2010]. Dieser Bericht konzentriert sich auf Methoden, die besonders für die oben geschilderte Problematik mit Open Data geeignet sind und zudem durch erprobte Software-Werkzeuge unterstützt werden.

Durch die Entwicklung des Semantischen Netzes (Semantic Web) sind auf KI-Methoden basierende Repräsentationsformen entscheidend gefördert worden [Hitzler et al. 2010]. Das zentrale Ziel des Semantischen Netzes besteht darin, die Vielfalt der im WWW (World Wide Web) gespeicherten Daten unter Wahrung ihrer Bedeutung mit dem Computer verarbeiten zu können. Dieses Ziel deckt sich in hohem Maße mit den oben umrissenen Anforderungen an die Verarbeitung von Open Data. Die für das WWW entwickelten Verfahren sind teilweise bereits standardisiert, es entstehen aber weiterhin neue Varianten, mit denen besonderen Anwendungsanforderungen begegnet werden kann.

Kernstück des Semantischen Netzes ist die Verwendung von eindeutigen Bezeichnern für Datenklassen (Konzepte, Kategorien) und Beziehungen (Relationen) zwischen Daten. Dies wird im Folgenden anhand einer "Busfinder"-App verdeutlicht. Sie zeigt einem Fußgänger den Weg zur nächstliegenden Bushaltestelle, von der aus ein Zielort möglichst schnell erreicht werden kann. Offenbar müssen mehrere Datenquellen miteinander verknüpft werden: Ein Stadtplan mit Buslinienverläufen, die zugehörigen Busfahrpläne, der augenblickliche Standort des Fußgängers und die aktuelle Zeit. In Abbildung 1 wird (vereinfacht) illustriert, wie die Daten durch standardisierte Kategorien und Relationen maschinenlesbar und bedeutungsbewahrend repräsentiert werden können.

Kategorien lassen sich als Wertemengen verstehen. Eine grundlegende Beziehung zwischen Mengen ist "hat-Teilmenge", über die Eigenschaften und Beziehungen vererbt werden. Die Beziehung "hat-Element" setzt eine Kategorie zu einem konkreten Wert

(einer Instanz) aus der Wertemenge in Beziehung. Auch hier werden Eigenschaften und Beziehungen vererbt.

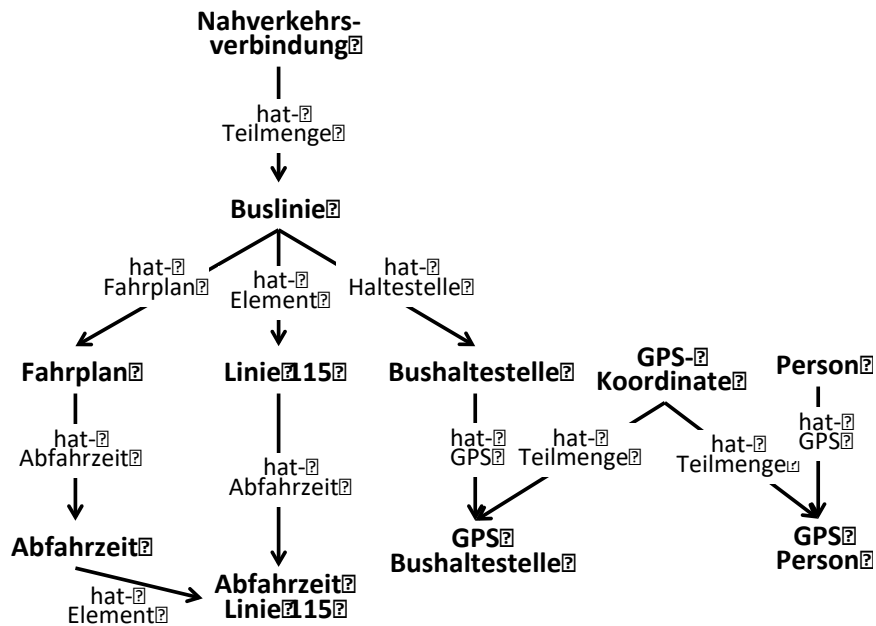


Abbildung 1: Kategorisierungen und Beziehungen für Daten der Busfinder-App

Mit einer so strukturierten Wissensrepräsentation kann ein Mehrwert in vielfacher Hinsicht erzeugt werden:

- (i) Man kann auf effiziente und teilweise standardisierte Software-Komponenten zurückgreifen, die konkrete Anwendungsentwicklungen wesentlich erleichtern, z.B. eine passende Datenbank, Anfragedienste, Editoren und Inferenzsysteme.
- (ii) Die Konsistenz einer Wissensbasis wird gesichert. Widersprüchliche Definitionen von Kategorien oder Relationen werden automatisch als "unerfüllbar" erkannt.
- (iii) Implizite, nicht offensichtliche Zusammenhänge werden bei Anfragen automatisch mit ausgewertet (anders als bei Datenbankabfragen).

Voraussetzung für diese Vorteile ist ein gemeinsames Datenmodell für alle in der Wissensbasis integrierten Datenquellen. Dies ist bei großen, gewachsenen Unternehmen durchaus nicht leicht zu erzielen, wenn auch im Hinblick auf einen hohen IT-Standard in jedem Fall erstrebenswert.

Im Folgenden werden verschiedene konkrete Realisierungsformen für Wissensrepräsentation mit KI-Methoden beschrieben.

3.2.1. OWL

Unter dem Namen OWL (Web Ontology Language) sind Syntax und Semantik von Ontologiesprachen für das Semantische Netz niedergelegt und als Standards empfohlen worden [OWL 2011]. Es werden drei Varianten unterschieden:

OWL DL umfasst im Wesentlichen Ausdrucksformen, die in langjährigen KI-Forschungen zu Beschreibungslogiken (Description Logics) untersucht worden sind [Baader et al.

2010]. Mit OWL DL wird eine Sprache größtmöglicher Ausdrucksstärke bereitgestellt, ohne dass eine Konsistenzprüfung unentscheidbar wird (wie es in allgemeinen bei prädikatenlogischen Ausdrücken der Fall wäre). Für OWL DL existieren zahlreiche Werkzeuge und kommerziell erhältliche Inferenzsysteme.

OWL Full umfasst alle Sprachkonstrukte von OWL DL, bietet jedoch zusätzlich noch Formulierungsmöglichkeiten für prädikatenlogische Ausdrücke höherer Ordnung. Damit wird OWL Full unentscheidbar, d.h. Inferenzverfahren können unvollständig sein oder sogar nicht terminieren.

OWL Lite wurde als eine Sprache entwickelt, mit der man Taxonomien einfach formulieren und Inferenzen effizient durchführen kann. OWL Lite enthält eine Teilmenge der Ausdrucksmöglichkeiten von OWL DL.

Alle OWL-Dialekte basieren auf dem Standard RDF (Resource Description Framework) bzw. RDF-Schema. Damit sind APIs (Application Programming Interfaces) für RDF und weitere Werkzeuge verwendbar.

3.2.2. LINKED OPEN DATA

Das WWW kann auch unmittelbar zur Verknüpfung und Vernetzung von Daten eingesetzt werden. Dazu ist das Linked Open Data Format geschaffen worden, in dem Daten in HTTP-Syntax als Knoten eines weltweit zugänglichen Netzes gespeichert werden. Nach Tim Berners Lee gelten die folgenden Regeln:

1. Zur eindeutigen Bezeichnung von Objekten werden URIs (Universal Resource Identifiers) verwendet.
2. Es werden HTTP-URIs verwendet, mit denen sich Bezeichnungen jederzeit nachschlagen lassen.
3. Es werden zweckdienliche Informationen bereitgestellt, wenn jemand eine URI mittels des Standards RDF und der Anfragesprache SPARQL nachschlägt.
4. Zu diesen Informationen gehören insbesondere Links auf andere URIs, über die weitere Objekte entdeckt werden können.

Bei Verwendung von RDF-Schema stehen auch Inferenzmethoden (und entsprechende Werkzeuge) zur Verfügung, jedoch mit beschränkter Ausdruckskraft im Vergleich zu OWL. Z.B. können keine negativen Aussagen formuliert und in Inferenzsystemen ausgewertet werden. Aufgrund der einfachen Tripelstruktur von RDF analog zu einer Graphstruktur mit Knoten und Kanten ist dieses Datenformat jedoch ein weit verbreitetes Mittel, Beziehungen zwischen Daten eindeutig auszudrücken.

Für Open Data aus dem Verwaltungsbereich ist das gemeinsame Metadatenmodell *DCAT-AP.de* (deutsche Variante des europäischen "Data Catalogue Application Profile") definiert worden. Es entspricht im Wesentlichen dem RDF-Format und erlaubt den Zugriff mit entsprechend standardisierter Software. Damit bietet DACT-AP die gleichen Schlussfolgerungsmöglichkeiten wie RDF-Schema, z.B. die Möglichkeit, Ontologien mit entsprechenden Inferenzverfahren einzurichten und eine semantische Suche zu unterstützen. Allerdings haben die Daten, die sich in aktuellen gemäß DACT-AP strukturierten Dateien finden, fast ausschließlich den Typ "Text", nur wenige Felder enthalten nicht-textuelle Daten, insbesondere Verweise. Bei der Entwicklung von Apps für Open Data können deshalb in der Regel weitere Inferenzmöglichkeiten durch Überführung in OWL-Repräsentationen gewonnen werden.

3.2.3. KNOWLEDGE GRAPHS

Mit Knowledge Graph wird eine von Google verwendete Technologie bezeichnet, die intelligente Antworten auf Suchanfragen ermöglichen soll. Ihr zugrunde liegt eine semantische Vernetzung, ähnlich den Semantischen Netzen aus der Frühzeit der KI [Minsky 1968]. Mit der Knowledge Graph Technologie können Begriffe mit ihrem Kontext und zusätzlichen Informationen verbunden werden. Für einen Benutzer der Suchmaschine ergeben sich mehrere Vorteile: (i) Mehrdeutigkeiten können leicht aufgelöst werden, (ii) relevante Daten können in einer Zusammenfassung präsentiert werden, und (iii) Verbindungen zu möglicherweise interessanten Zusatzinformationen werden sichtbar.

Im Gegensatz zur Wissensrepräsentation mit OWL ermöglicht die Vernetzung in einem Knowledge Graph keine tiefgehenden formalen Inferenzen, sondern repräsentiert hauptsächlich assoziative Beziehungen zwischen Daten. Bei der Entwicklung von Anwendungen für Open Data im Mobilitätsbereich wird zu prüfen sein, ob die Daten hinsichtlich Heterogenität und Umfang den Big Data von Google entsprechen und eine assoziative Verknüpfung sinnvoll ist.

3.2.4. REGELBASIERTE SYSTEME

Die in den 80er Jahren geschaffenen Techniken zur Wissensrepräsentation mit Regeln (oder Produktionen) und zur Wissensverarbeitung durch datengetriebene Regelanwendung hatten ihre größte Bedeutung bei der Entwicklung von Expertensystemen. Expertenwissen wird dazu in Wenn-Dann-Regeln deklarativ formuliert:

WENN <Bedingungsteil> DANN <Aktionsteil>

Bei Vorwärtsverkettung wird ein konkretes Problem durch Angabe der Faktenlage beschrieben. Daraus werden dann durch wiederholte Regelanwendungen Konsequenzen abgeleitet. Bei Rückwärtsverkettung werden Probleme durch Zielvorgaben, also gewünschte Konsequenzen, beschrieben. Regelanwendungen ermitteln daraus die notwendigen faktischen Voraussetzungen.

Regeln eignen sich zur deklarativen Wissensrepräsentation, solange die Wissensbasis übersichtlich bleibt (< 1000 Regeln) und Änderungen nicht zu Konsistenzverlust führen. In modernen KI-Systemen kann ein regelbasiertes System als eingebettete Komponente enthalten sein. Regeln werden dann häufig durch Lernverfahren generiert oder aus ontologiebasiertem Wissen abgeleitet.

3.2.5. DEDUKTIVE DATENBANKEN

Will man an klassischen Datenbanken, z.B. Relationalen Datenbanken, festhalten, so können diese dennoch um Inferenzmöglichkeiten erweitert werden. Prominenter Vertreter solcher Dienste ist *Datalog*. Datalog erlaubt es, das relationale Datenmodell mit einer logikbasierten Deduktionskomponente zu verbinden. Anders als bei OWL DL, (s.o.) ist die Ausdruckskraft eingeschränkt. Es können Regeln der folgenden Form verarbeitet werden:

$$p(X_1, \dots, X_m) :- q^1(A^1_1, \dots, A^1_{m_1}) \wedge \dots \wedge q^n(A^n_1, \dots, A^n_{m_n})$$

p und q^i sind Prädikate, X_i sind Variable, A_k sind Variable oder Konstanten. Lassen sich die Prädikate q^i rechts des Trennzeichens in der Datenbank instanziiieren, so wird das Prädikat p links des Trennzeichens abgeleitet. Für den Aufbau der Regeln gelten zusätzliche Einschränkungen, aber ihr Anwendungspotenzial ist offensichtlich. Z.B. könnten aus Wetterdaten, Verkehrsdaten und anderen Einflussgrößen automatisch kritische Schadstoffsituationen abgeleitet werden.

Neben der strukturierten Datenrepräsentation in relationalen Datenbanken ist eine deklarative Repräsentation von Inferenzregeln erforderlich, die in der Regel manuell erstellt werden müssen und bei größerer Anzahl schnell unübersichtlich werden. Die weiter unten beschriebenen Verfahren zum Maschinellen Lernen bieten hier in teilweise Abhilfe.

3.2.6. ONTOLOGIEABGLEICH

Zur Auswertung komplexer Datenbestände müssen häufig Datenströme aus verteilten Systemen zusammengeführt werden, die unter Verwendung unterschiedlicher Ontologien entstanden sind. Zum Abgleich von Ontologien (Ontology Alignment) sind in der KI verschiedene Techniken entwickelt worden [Bellahsene et al. 2011], mit denen Datenfelder unterschiedlicher Quellen in eine gemeinsame Repräsentation überführt werden können. Die Problematik wird in Abbildung 2 anhand der Zusammenführung von Unfalldaten und Wetterdaten illustriert.

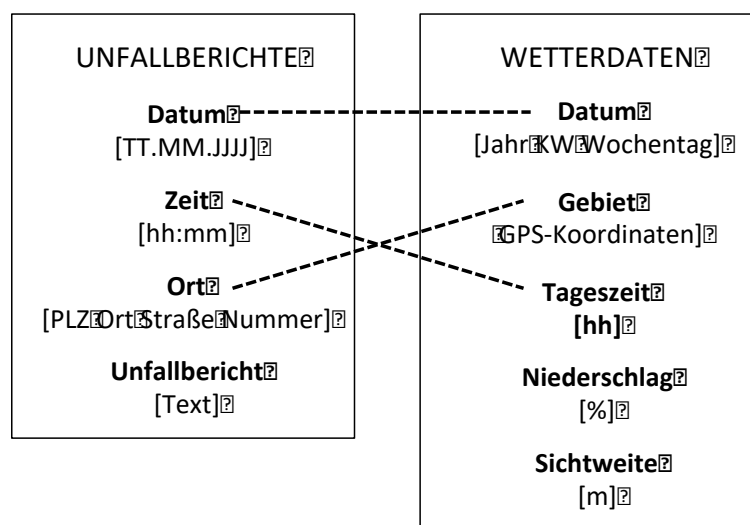


Abbildung 2: Ontologieabgleich für semantisch überlappende Datensätze am Beispiel der Zusammenführung von Unfallberichten mit Wetterdaten.

Wie im Beispiel gezeigt, können Datenfelder in der Regel nicht anhand gleicher Bezeichner zugeordnet werden. Zum Abgleich sind semantische und strukturelle Beziehungen heranzuziehen, gegebenenfalls auch Kontextinformationen, mit denen eine ontologische Verortung unterstützt werden kann.

3.3. KI-METHODEN ZUR DATENANALYSE UND -AUFBEREITUNG

Open Data-Initiativen bieten neben der für viele öffentliche Daten erstrebenswerten Transparenz auch und vor allem die Möglichkeit, neue Dienste anzubieten, interessante neue Aussagen abzuleiten und neue Einsichten zu gewinnen. Hierfür gibt es in der KI eine Vielzahl von Methoden, einige davon noch Gegenstand von Forschung und Entwicklung, viele aber schon in Anwendungen bewährt und durch entsprechende Werkzeuge unterstützt.

Es ist nicht immer klar, was eine "KI-Methode" ist. Man kann auch feststellen, dass KI-Methoden in dem Maße, wie sie praktische Verwendung finden, in den allgemeinen IT-Methodenschatz integriert werden. In umgekehrter Richtung werden Methoden anderer Disziplinen, z.B. der Statistik, in KI-Verfahren integriert. Wir nehmen hier den Blickwinkel von KI-Wissenschaftlern ein und konzentrieren uns auf Verfahren, die für Anwendungen von Open Data im Hinblick auf heterogene und große Datenbestände besonders relevant sind.

3.3.1. SUCHVERFAHREN

Suchverfahren sind schon frühzeitig Gegenstand von KI-Knowhow gewesen, insbesondere die sog. A*-Suche. Dabei geht es um die Suche eines optimalen Pfades bei gegebener Kostenfunktion für Problemstellungen, in denen mit vielen Teilentscheidungen ein Weg zum Ziel gefunden werden muss, z.B. bei der Routenplanung im Straßenverkehr oder der Handlungsplanung in der Robotik. Verfahren auf der Basis der A*-Suche gehören mittlerweile zum IT-Repertoire und bedürfen keiner besonderen Hervorhebung in diesem Bericht. Eine umfassende Darstellung findet sich in [Edelkamp und Schroedl 2011].

Ein mit semantischen Repräsentationsverfahren einhergehendes Suchverfahren ist die *Semantische Suche*. Damit können Zugriffe auf Daten über ihren Bedeutungskontext erfolgen, ohne dass die Daten direkt adressiert werden. Sollen beispielsweise Unfallberichte ausgewertet werden, können "Zusammenstöße bei Regen" über die entsprechenden semantischen Kategorien der zugehörigen Ontologie ermittelt werden.

Dasselbe Prinzip kann auch bei inhaltsbasiertem Bildzugriff (Content-based Image Retrieval, CIR) zum Tragen kommen. Z.B. können bei der Suche nach Bildern mit vierspurigem Autobahnverkehr die gewünschten inhaltlichen Kategorien und Eigenschaften als Index verwendet werden. Dies setzt allerdings voraus, dass die Bildinhalte eines Archivs entsprechend semantisch repräsentiert sind. Derzeit dominieren Zugriffe über textuelle Bildtitel und Ähnlichkeit auf der Bildebene, semantischer Bildzugriff ist noch nicht ausgereift (siehe dazu auch Abschnitt 4.3).

Weiterentwicklungen der Semantischen Suche werden letzten Endes auch zu multimodalen Suchverfahren führen, bei denen Bild- und Textinformationen im Zusammenhang ausgewertet werden. Ein solcher Ansatz ist für alle Daten plausibel, deren Bedeutung unabhängig vom Beschreibungsmodus ist, z.B. bei Realweltvorgängen und -fakten. Multimodaler Datenzugriff ist ein aktiver Forschungsbereich der KI.

Suchverfahren der KI stehen im Open Data-Kontext vorwiegend als Bestandteile der Infrastruktur und als Hilfsmittel zur Verfügung.

3.3.2. LERNVERFAHREN

Über Erfolge mit KI-Lernverfahren auf der Basis Künstlicher Neuronaler Netze (KNN) ("Deep Learning") ist in jüngster Zeit viel berichtet worden. Die Attraktivität dieser Verfahren beruht darauf, dass bei der Entwicklung von Analyseverfahren das Bereitstellen einer großen Zahl von Lernbeispielen und die Verwendung von Standardverfahren an die Stelle von möglicherweise komplexer Programmierung, verbunden mit unzureichender Performanz, treten kann. Open Data im Mobilitätsbereich werden voraussichtlich große Datenbestände mit vielen Beispielen enthalten, so dass die Voraussetzungen für die Verwendung von KNN erfüllt sein können. In den folgenden Abschnitten werden auf KNN basierende Lernverfahren und ihre Anwendung bei Open Data im Einzelnen vorgestellt. Eine umfassende und vertiefende Darstellung findet sich in [Goodfellow et al. 2016].

ÜBERWACHTES LERNEN

Bei Überwachtem Lernen geht es darum, Klassifikatoren herzustellen, mit denen Daten gewünschter Charakteristika bestimmt werden können. Dazu werden dem Lernsystem positive Beispiele mit den klassenbestimmenden Merkmalen vorgelegt. In einem iterativen Verfahren klassifiziert das System diese Beispiele versuchsweise und erhält dabei vom Lehrer (bzw. von den Labels der Lernbeispiele) eine Rückmeldung, ob die Klassifikation korrekt war. Auf der Basis dieser Rückmeldung verändert das System ggf. den Klassifikator durch Justieren der Gewichte einzelner Zellen im KNN. Dies muss in einem je nach Aufgabe langwierigen Prozess viele Male und mit manchmal Tausenden von Beispielen wiederholt werden, bis die Fehlerquote des gelernten Klassifikators genügend niedrig ist.

Überwachtes Deep Learning eignet sich besonders für Klassifizierungsaufgaben, die sich auf eine Vielzahl von Merkmalen und auf nicht offensichtliche Zusammenhänge zwischen Merkmalen und Klasse stützen müssen. Z.B. könnte man versuchen, einen Klassifikator für gefährliche Straßenabschnitte anhand von Lernbeispielen aus Unfallberichten und Merkmalen wie Verkehrsdichte, Straßenbreite, Verlauf, Geschwindigkeitsbeschränkung, Fahrbahndecke, Beleuchtungsverhältnisse, Art der Umgebung etc. zu erlernen. Der Klassifikator könnte dann bei der Planung von Straßen Vorhersagen hinsichtlich der Unfallgefahr ermöglichen.

Das Beispiel soll nur der Illustration dienen, vermutlich gibt es in diesem Anwendungsbereich schon ausreichendes menschliches Expertenwissen. Gleichzeitig kann am Beispiel aber auch ein Nachteil der KNN verdeutlicht werden: Vom gelernten Klassifikator kann man nicht ohne Weiteres erfahren, aufgrund welcher Merkmale oder welcher besonderen Merkmalskonstellationen eine positive Klassifikation erfolgt ist. KNN sind also Schwarze Kästen (Black Boxes), deren Innenleben schwer interpretierbar ist.

Neben Deep Learning gibt es weitere erprobte KI-Lernverfahren, die auch bei Open Data-Anwendungen in Betracht gezogen werden sollten, speziell dann, wenn die Voraussetzungen für Deep Learning nicht optimal gegeben sind. Zu nennen sind hier besonders *Entscheidungsbäume*, die aus Lernbeispielen automatisch gewonnen werden können. Ein Entscheidungsbaum erzielt eine Klassifizierung durch die sukzessive individuelle Bewertung der einzelnen Merkmale. Der von einem Entscheidungsbaum für eine bestimmte Klasse gelernte Teilraum des Merkmalsraumes (mit einer Dimension für jedes Merkmal) hat dann also notwendigerweise Grenzflächen senkrecht zu einzelnen Koordinatenachsen. Dieser Einschränkung unterliegen die mit einem KNN gelernten Klassifikatoren nicht.

UNÜBERWACHTES LERNEN

Deep Learning eignet sich auch für Aufgaben, bei denen man Strukturen in großen unübersichtlichen Datenmengen finden möchte. Beispielsweise könnte man bei den Fahrgastströmen im Öffentlichen Personennahverkehr (ÖPNV) an ausgeprägten Start-Ziel-Mustern interessiert sein. Die dazu verwendbaren Lernverfahren unterscheiden sich nicht wesentlich von denen des Überwachten Lernens, denn in den Daten vorhandene Merkmale können einfach als Label interpretiert werden. Bei der Analyse von Fahrgastströmen könnte man z.B. bestimmte Wohnbezirke als Label verwenden und einen Klassifikator lernen, der Fahrgastströme aus diesen Wohnbezirken positiv klassifiziert. Durch eine geeignete Dimensionierung des KNN können die typischen Ziele dieses Fahrgaststroms ausgewiesen und untypische Ziele unterdrückt werden.

Eine weitere Anwendungsmöglichkeit ist das Entdecken von Anomalien, z.B. außergewöhnlichen Situationen oder Vorgängen. Deep Learning dient hierbei dazu, ein probabilistisches Modell für Normalfälle zu lernen. Eine Anomalie wird dann anhand ihrer geringen Wahrscheinlichkeit erkannt.

Das Ziel, komplexe große Datenmengen in vereinfachten Verteilungen zu repräsentieren und damit Einsichten in interessante Zusammenhänge zu gewinnen, kann auch mit einer *Hauptkomponenten-Analyse* (Principal Component Analysis, PCA) erreicht werden, einem in der KI schon seit vielen Jahrzehnten bekannten Verfahren [Dunteman 1989]. Ausgangspunkt für eine PCA ist die Kovarianzmatrix der Daten, in der sich, gemittelt über alle Daten, die statistischen Zusammenhänge zwischen Paaren von Merkmalen widerspiegeln. Durch Diagonalisierung dieser Matrix kann ein transformierter Merkmalsraum gewonnen werden, in dem die neuen Merkmale statistisch entkoppelt sind und ihr Einfluss auf die Gesamtverteilung erkennbar ist. Durch Weglassen der unbedeutenden (neuen) Merkmale entsteht eine vereinfachte Sicht auf die Daten, mit der typische Vertreter von untypischen unterschieden werden können. Z.B. könnte damit die Visualisierung von potenziellen Ursachen für Schadstoffbelastung vereinfacht werden. Das Verfahren ist wenig aufwändig, berücksichtigt allerdings nur die Kovarianzen der Daten, also keine Eigenschaften höherer Ordnung.

Ein weiteres, schon vielfach verwendetes Verfahren zur Entdeckung von Gruppierungen in Datenmengen ist das *k-Means-Clustering*. Es ist anwendbar, wenn die Daten - wie in den bisher geschilderten Verfahren - in Gestalt von Merkmalsvektoren vorliegen und eine feste Anzahl von k Klassen (Clustern) vorgegeben werden kann. Das Verfahren bestimmt k Klassenzentren in einem iterativen Verfahren, bei dem Datenvektoren im Merkmalsraum dem jeweils nächstliegenden Zentrum zugeordnet werden, und die Zentren dann in den Schwerpunkt der ihnen zugeordneten Daten verschoben werden. In dem oben verwendeten Beispiel über Fahrgastströme könnten auf diese Weise k ausgeprägte Start-Ziel-Muster bestimmt werden.

Als letztes Beispiel für KI-Verfahren zum Entdecken von Strukturen in Datenbeständen soll *Data-Mining* kurz skizziert werden. Data-Mining hat Wurzeln in Statistik und Mustererkennung und ist in der KI auch im Zusammenhang mit Wissensentdeckung (Data Mining and Knowledge Discovery, DMKD) bekannt. Eine typische Anwendung von Data-Mining besteht darin, statistisch ausgeprägte Assoziationen zwischen Merkmalen von Daten zu finden. Z.B. könnte man damit das Einkaufsverhalten von Fluggästen in den Flughafen-Shops analysieren. Fluggäste müssen dazu häufig ihre Bordkarte vorlegen, so dass Flugziele und andere Fluggastdaten mit den Einkäufen assoziiert werden können. Data-Mining sucht nun in systematischer Weise nach Regeln der Form "Wenn X, dann Y", wobei X z.B. ein Kundenmerkmal und Y ein Warentyp ist. Eine Regel wird nur dann vermutet, wenn genügend viele Beispiele mit X und Y vorhanden sind, und die Vorhersagekraft der Regel genügend groß ist.

Zu allen genannten Verfahren gibt es eine Vielzahl von Varianten, auf einschlägigen wissenschaftlichen Konferenzen werden jährlich Verfeinerung und Neuerungen vorgestellt. Es darf nicht unterschätzt werden, dass die hier konzeptuell beschriebenen Verfahren durchaus beträchtlichen Aufwand bei der Aufbereitung der Daten erfordern können, bevor man die Daten dem eigentlichen Analyseverfahren unterziehen kann. Z.B. muss für Data-Mining eine geeignete Diskretisierung von Merkmalen vorgenommen werden, damit interessante Assoziationen gefunden werden können. Sind die Merkmale zu differenziert, gibt es zu wenig Beispiele für einzelne Regelkandidaten.

3.3.3. FALLBASIERTES SCHLIEßEN

Die in den Abschnitten 3.2.1 und 3.2.2 beschriebenen Verfahren erfordern in der Regel eine große Anzahl von Beispielen, um gute Lernergebnisse erzielen zu können. Es gibt jedoch auch zahlreiche Problembereiche, in denen dies nicht möglich ist, z.B. bei der Bekämpfung von Katastrophen oder bei der Behandlung von außergewöhnlichen Verkehrssituationen. Hier kann Fallbasiertes Schließen (Case-based Reasoning, CBR) zum Einsatz kommen, eine schon frühzeitig in der KI entwickelte Methodik [Kolodner 1993]. Die Grundidee besteht darin, Probleme durch Vergleich mit bekannten Problemfällen zu lösen. Dazu wird der vorliegende Fall anhand von Merkmalen mit der Falldatenbasis verglichen, und der "ähnlichste" bekannte Fall wird zur Lösung herangezogen.

Zur Gewährleistung von Vergleichbarkeit müssen die Fälle natürlich wohlstrukturiert und unter Verwendung semantischer Kategorien beschrieben werden, so dass z.B. geprüft werden kann, ob ein gespeicherter Fall den aktuellen Fall subsumiert. Problematisch bleibt jedoch oft die Definition eines geeigneten Ähnlichkeitsmaßes, mit dem auf heterogenen Merkmalen beruhende Unterschiede zusammengefasst werden können.

3.3.4. EMPFEHLUNGSDIENSTE

In den letzten Jahren haben Empfehlungsdienste (Recommender Systems) viel Aufmerksamkeit in der KI erhalten [Ricci et al. 2011] und sind auch schon im praktischen Einsatz, z.B. um Amazon-Kunden Kaufempfehlungen zu geben. Der Nutzen eines Empfehlungsdienstes kann darin bestehen, Benutzern die Auswahl von Objekten (Produkten, Nachrichten, Musikstücken etc.) aus einer unübersichtlichen Objektmenge zu erleichtern oder Anbietern gezielte Werbung zu ermöglichen. Für Open Data-Anwendungen ist die Auswahlunterstützung von Benutzern besonders interessant, da es sich dabei um sehr große, unübersichtliche Datenvolumina handeln kann.

Man unterscheidet *inhaltsbasierte* und *kollaborative* Empfehlungen, je nachdem, ob das bisherige Auswahlverhalten des Benutzers oder das vergleichbarer anderer Benutzer ausgewertet wird. In beiden Ansätzen kommen meist KI-Lernverfahren zur Anwendung. Bei inhaltsbasierten Empfehlungen wird aus den bisherigen Entscheidungen des Benutzers ein Klassifikator erlernt, der aus dem Gesamtangebot die für ihn möglicherweise interessantesten Objekte herausfiltert. Bei kollaborativen Empfehlungen müssen vergleichbare Benutzer mithilfe eines Klassifikators für Benutzer mit ähnlichem Profil herausfiltert werden. Deren Auswahlverhalten kann dann als Basis für Empfehlungen verwendet werden.

Die Lernaufgaben können auf verschiedene Weise gelöst werden, darunter auch Deep Learning. Unterschiede ergeben sich je nachdem, ob Daten online oder speicherbasiert ausgewertet werden müssen. Ein Klassifikator kann auch als deklaratives Modell mit semantischer Wissensrepräsentation gelernt werden. Dies hat den Vorteil, dass gelernte

Auswahlkriterien explizit gemacht werden können. In jedem Falle spielen KI-Methoden eine bedeutende Rolle.

3.3.5. BAYES NETZE

Bayes Netze, eine besondere Form von Graphischen Modellen, sind ein aus der Statistik bekannter Formalismus, mit dem unsichere Zusammenhänge zwischen probabilistischen Einflussgrößen kompakt dargestellt und analysiert werden können. In der KI und Big Data spielen Bayes-Netze eine bedeutende Rolle, denn in vielen Anwendungen müssen probabilistische Informationen aufbereitet und für Vorhersagen oder Ursachenforschung ausgewertet werden. Ein Bayes-Netz wird in der Regel aus gesammelten Falldaten gewonnen, also einem aufgezeichneten Erfahrungsschatz oder experimentellen Daten.

Mit Bayes-Netzen werden multivariate Verteilungen in Gestalt eines gerichteten azyklischen Graphen (Directed Acyclic Graph, DAG) repräsentiert. Dabei werden die Zufallsvariablen als Knoten und ihre unmittelbaren Abhängigkeiten als Kanten dargestellt. Jeder Knoten besitzt eine bedingte Wahrscheinlichkeitsverteilung, mit der die probabilistische Abhängigkeit der Knotenvariablen von den unmittelbaren Vorgängern im DAG spezifiziert wird. Abbildung 3 zeigt ein Bayes-Netz, mit dem der Zeitverlust auf einem Straßenabschnitt modelliert wird.




Abbildung 3: Bayes-Netz für die Schätzung von Zeitverlust auf einem Straßenabschnitt

Die Verbundverteilung lässt sich dann auf der Basis der bedingten Knotenwahrscheinlichkeiten wie folgt berechnen (mit abgekürzten Knotennamen):

$$P(\text{GR, TA, WO, WE, BA, VE, ZE}) = P(\text{ZE} \mid \text{VE, WE, BA}) * P(\text{VE} \mid \text{GR, TA, WO}) * P(\text{GR}) * P(\text{TA}) * P(\text{WO}) * P(\text{WE}) * P(\text{BA})$$

Die kompakte Repräsentation ermöglicht effiziente Vorhersagen, auch bei Berücksichtigung einer großen Zahl von Einflussfaktoren. Sind die Abhängigkeiten nicht bekannt, so kann mit speziellen Verfahren nach einer DAG-Struktur gesucht werden, die die vorliegende Statistik am besten erklärt. Ist man an kausalen Deutungen interessiert, so reicht die gute Modellierung von Korrelationen allerdings nicht aus, Kausalität muss durch den Effekt von sog. Interventionen nachgewiesen werden [Pearl et al. 2016].

Ein Vergleich mit gelernten KNN-Klassifikatoren zeigt interessante Unterschiede: Im Gegensatz zu KNN sind in Bayes-Netz-Strukturen einzelne Einflusspfade und intermediäre Faktoren sichtbar. Weiterhin erlauben Bayes-Netze beliebige Inferenzen von bekannten auf unbekannte Größen, nicht nur von vordefinierten Eingangsgrößen auf vordefinierte Ausgangsgrößen.

3.3.6. PLANEN

Das Berechnen von Plänen zur Erreichung von Zielen ist eines der ältesten Themen der KI. Planungsmethoden der ersten Generation basieren vielfach auf STRIPS (Stanford Research Institute Problem Solver) aus dem Jahr 1971. STRIPS bietet eine formale Sprache, in der Zustandsveränderungen durch eine Aktion beschrieben werden können. Der Planungsprozess ist im Wesentlichen eine Suche nach einer Folge von Aktionen, die einen Anfangszustand in einen gewünschten Zielzustand überführt.

Moderne KI-Planungsverfahren sind in vieler Hinsicht leistungsfähiger als ein einfaches STRIPS-basiertes Verfahren. Eine wichtige Erweiterung besteht darin, Handeln von multiplen Agenten planen und koordinieren zu können. Hierfür sind manuelle Verfahren wegen des meist unübersichtlichen Suchraumes nicht mehr geeignet. Mit modernen KI-Verfahren stehen Lösungsmöglichkeiten für zahlreiche aktuelle Anwendungsbereiche zur Verfügung, z.B. den Einsatz von Werkzeugmaschinen zur Produktfertigung, Steuerung multipler Fahrstühle, Einsatz von Assistenzrobotern zusammen mit Menschen, Logistik für Fernlastverkehr u.a. Häufig werden im Zusammenhang mit konkreten Anwendungsaufgaben auch besonders effiziente Verfahren für Big Data entwickelt. Eine klare Abgrenzung zwischen KI und modernen IT-Verfahren ist hierbei nicht immer möglich und sinnvoll.

Für den Mobilitätsbereich spielt Routenplanung eine besondere Rolle. Hier kommt grundsätzlich das oben genannte Suchverfahren A* zum Einsatz. Dabei werden die bestbewerteten Wegverbindungen mit einem heuristischen Verfahren, aber ohne Verlust der Optimalität, aus einer potentiell sehr großen Menge möglicher Verbindungen ermittelt. Deutliche Effizienzverbesserungen für Online-Dienste werden durch das Horten von Zwischenergebnissen (Caching) erreicht.

3.4. BILDERVERARBEITUNG

Bildverarbeitung ist ein weitgehend eigenständiger Bereich der KI. Der Methodenschatz umfasst Verfahren zur Bildaufbereitung und Objekterkennung bis hin zur Szenenanalyse, also zur inhaltlichen Beschreibung komplexer Situationen und Abläufe. Viele Verfahren zur Bildaufbereitung gehören heute zum Standardrepertoire, bekannt z.B. von Werkzeugen wie Photoshop, und werden hier nicht weiter beschrieben. Für Anwendungen im Mobilitätsbereich sind fortgeschrittene Verfahren zur Objekterkennung und Szenenanalyse von größter Bedeutung.

3.4.1. OBJEKTERKENNUNG

Die Möglichkeiten zur Objektklassifikation (Bestimmung des Objekttyps) und Objektidentifikation (Bestimmung einer Objektidentität) sind in der letzten Dekade durch Weiterentwicklung der KNN (Künstlichen Neuronalen Netze) entscheidend verbessert worden. Z.B. können Ansichten eines Autos relativ zuverlässig in Bildern von Straßenverkehr erkannt (d.h. als Auto klassifiziert) werden. Ein weiteres Beispiel sind Zugangskontrollsysteme, mit ihnen können Gesichter von berechtigten Personen korrekt identifiziert werden. Der Erfolg von auf KNN basierenden Systemen hängt entscheidend von einer genügend großen Zahl von Lernbeispielen ab. Dies ist beim Erlernen von Klassifikatoren häufig durch annotierte Bilder aus dem Internet gegeben. Stehen zu wenig Bilder zur Verfügung, besteht beim Lernen die Gefahr, dass von den Beispielen zu stark verallgemeinert wird, oder der Klassifikator zu stark auf die Beispiele zugeschnitten wird (Overfitting).

Lernverfahren für KNN werden in der Forschung immer noch weiterentwickelt. Z.B. sind erst kürzlich neue Methoden bekannt geworden, bei denen ein KNN nicht als Ganzes, sondern in "Kapseln" gelernt wird, wobei Kapseln einzelnen Merkmalen von Lernobjekten entsprechen. Daraus wird dann das endgültige KNN zusammengesetzt.

Objekterkennung wird umso schwieriger, je variabler das Aussehen einer Objektklasse ist, und je weniger sich Objekte verschiedener Klassen unterscheiden. Variabilität entsteht häufig durch wechselnde Perspektiven und unterschiedliche Wetter- und Beleuchtungsverhältnisse. Hier können Methoden der Szenenanalyse weiterhelfen, die es erlauben, Kontext mit einzubeziehen (s. den folgenden Abschnitt).

3.4.2. SZENENANALYSE

Szenenanalyse befasst sich (i) mit der Auswertung von Einzelbildern, bei denen es um Objekte in räumlichem Kontext geht, oder (ii) mit der Auswertung von Bildfolgen und Videos, bei denen das zeitliche Verhalten von Objekten bestimmt werden soll. Verfahren zur Szenenanalyse erfordern neben Objektklassifikation auch das Auswerten von räumlichen und zeitlichen Beziehungen zwischen Objekten und das Einbeziehen von Kontextinformationen verschiedenster Art, z.B. wenn ein Verkehrsunfall in einer Bildfolge erkannt werden soll.

Die Verwendung von KNN ist für komplexe Szenen in der Regel nicht geeignet, möglicherweise für die Erkennung einzelner darin enthaltener Objekte, jedoch nicht für die Vielfalt räumlich-zeitlicher Objektkonstellationen und Kontextbedingungen. Für

Szenenanalyse existieren aber andere erprobte Methoden, die in verschiedenen Anwendungsbereichen bereits erfolgreich eingesetzt wurden, z.B. zum Monitoring von Parkplätzen oder Bahnsteigen, oder zur gesundheitlichen Überwachung von gefährdeten Personen in Altersheimen. Die über Objekterkennung hinausgehenden Analyseleistungen basieren dann nicht auf gelernten Beispielen sondern auf vom Entwickler programmierten Verhaltensmodellen. Der Entwicklungsprozess ist deshalb meist weit aufwändiger als das Lernen von Beispielen zur Objekterkennung.

Durch das Verwenden von OWL-basierten Repräsentationen für Verhaltensmodelle und eine automatische Übersetzung in Erkennungsprogramme konnten allerdings in jüngster Zeit erhebliche Fortschritte bei der Entwicklung von Systemen zur Szenenanalyse erzielt werden [Bohlken et al. 2013].

3.4.3. INHALTSBASIERTER BILDABRUF

Verfahren, mit denen Bilder aus einer Bilddatenbasis anhand von vorgegebenen Bildinhalten abgerufen werden können, werden als "Inhaltsbasierter Bildabruf" (Content-Based Image Retrieval, CBIR) bezeichnet. Eine naheliegende Methode besteht darin, einen Anfragetext mit textuellen Bildunterschriften zu vergleichen. Dabei kommt es zu keiner Bildanalyse, deshalb wird diese Methodik hier nicht weiter betrachtet. Es geht im Folgenden um Verfahren, bei denen textuelle Bildunterschriften nicht zur Verfügung stehen. Der Abruf von zu einer Anfrage passenden Bildern muss also durch Vergleich von pixelbasierten Bildinformationen erfolgen. Anfragen können entweder textuell oder in Gestalt eines Beispielbildes vorliegen.

Bei einer textuellen Anfrage stehen meist Objekte im Fokus, die in den gesuchten Bildern sichtbar sein sollen. Hier können grundsätzlich die bereits beschriebenen Verfahren zur Objekterkennung verwendet werden. Allerdings sind für einen Online-Einsatz effizienzsteigernde Methoden erforderlich, z.B. Vorklassifizierungen von gespeicherten Bildern. Textuelle Anfragen können durch ein semantisches Begriffssystem unterstützt werden, mit dem Oberbegriffe oder Synonyme zur Suche mit ausgenutzt werden können.

Größere Herausforderungen bietet ein Abruf auf der Basis eines Beispielbildes. Bei einigen Anwendungen, z.B. bei der Erkennung von Mitarbeitern anhand von Gesichtsbildern im Rahmen von Zugangskontrollen, gibt es zuverlässige Lösungen, auch für andere ähnlich eingeschränkte Anwendungen, etwa bei der Erkennung individueller Fahrzeuge in Bildern von Straßenverkehr. Für die Mehrzahl denkbarer Anwendungen reicht der bloße Vergleich von äußerlichen Bildeigenschaften allerdings nicht aus, Bildinhalte müssen auf semantischer Ebene verglichen werden. Dazu können zwar die bereits beschriebenen Verfahren zur Objekterkennung hinzugezogen werden, Objekte allein reichen aber im Allgemeinen nicht aus, Bildinhalte zu definieren. Beispielbilder können komplexe Szenen darstellen, z.B. Unfallszenen im Straßenverkehr oder Stadtansichten. Eine Online-Behandlung derartiger Anfragen ist beim heutigen Stand der Technik noch nicht möglich.

3.5. SPRACHTECHNOLOGIE

KI-Sprachtechnologie ist - verglichen mit Bildverarbeitung - sehr weit fortgeschritten. Man unterscheidet die Verarbeitung von gesprochener Sprache (Speech) und geschriebener Sprache (Text). Für beide Bereiche sind sowohl KI-Analyse- als auch KI-Syntheseverfahren von Bedeutung. Z.B. werden bei gesprochenen Anfragen an Google (oder andere Dienste) Anfragesätze inhaltlich analysiert, Antworten können als Texte generiert oder in synthetischer Sprache hörbar gemacht werden. Damit stehen leistungsfähige Werkzeuge für Benutzungsschnittstellen vielerlei Art zur Verfügung, z.B. für Fahrerassistenzsysteme. Hier geht es naturgemäß um die Verarbeitung und Generierung gesprochener Sprache, um Ablenkungen von Fahrern zu minimieren.

Zur Beantwortung von textbasierten Anfragen verwendet Google die auf KNN beruhende Technologie Word2Vec, mit der Antworten auf der Basis von Wortähnlichkeiten generiert werden [Mikolov et al. 2013]. Der Vergleich beruht auf Vektordarstellungen von Worten in einem hochdimensionalen Vektorraum. Jedes Wort ist darin als Vektor mit einer großen Zahl von Merkmalen (zwischen 100 und 1000) repräsentiert. Die Merkmale sind vorher mit einem KNN aus einem großen Korpus von Dokumenten gelernt worden und beschreiben, welche anderen Worte häufig in ihrer Umgebung auftreten.

Neben diesen schon beinahe alltäglichen Techniken gibt es einige neuere Entwicklungen der Sprachtechnologie, die weitergehende Möglichkeiten eröffnen. Als erstes sind Verfahren zur *Textzusammenfassung* zu erwähnen (Text Summarization). Damit können längere Texte in wenigen Sätzen zusammengefasst werden. Dies geschieht meist durch Identifizieren von Schlüsselwörtern (z.B. Personen, Orten) und Extrahieren von relevanten Aussagen. Das Bestimmen von Schlüsselwörtern wird auch zur *Themenerkennung* (Topic Recognition) von Dokumenten verwendet und liefert eine semantische Indizierung zur Unterstützung von Anfragen.

Textauswertung wird auch in zunehmendem Maße auf den Nachrichtenverkehr in sozialen Netzwerken angewendet. Eine kommerziell besonders interessante Variante ist die *Sentimentanalyse*. Hiermit soll das Publikumsecho auf Ereignisse oder Veranstaltungen bestimmt werden. Trotz der zuweilen unzureichenden Behandlung von negierten oder ironischen Aussagen kann bei der Auswertung einer genügend großen Zahl von Meinungsäußerungen ein bemerkenswert exaktes Gesamtbild gewonnen werden. Z.B. konnten Besucherzahlen für Filme durch die Analyse von Twitter-Nachrichten anlässlich der Filmankündigungen genauer vorhergesagt werden als durch trainierte Expertensysteme.

3.6. ROBOTIK

Robotik ist die "intelligente Verbindung von Wahrnehmung und Handeln" [Russell & Norvig 2010]. Robotik umfasst deshalb viele der bereits beschriebenen KI-Methoden, jedoch auch spezielle Verfahren für typische Robotik-Aufgaben, z.B. Auswerten von multimodalen Sensorsignalen, Navigieren in bekannter und unbekannter Umgebung, Greifen und Manipulieren von Gegenständen.

Im Zusammenhang mit Mobilitätsdaten ist natürlich das Navigationsverhalten autonomer Fahrzeuge von Interesse. Dazu gehören in erster Linie das Folgen oder Wechseln einer Fahrspur, das Erkennen von Verkehrsschildern und Ampeln, sowie die Erkennung von Hindernissen. Jede dieser Kompetenzen wird durch ein komplexes Zusammenspiel multipler Sensorik und darauf angepasster Verarbeitungsverfahren erreicht. Einzelne KI-Methoden lassen sich dabei schwer identifizieren und in diesen Bericht aufnehmen.

3.7. ABSCHLIEßENDE BEWERTUNG

Der kurze Rundgang durch die KI, mit besonderem Augenmerk auf die Verarbeitung von Big Data aus dem Mobilitätsbereich, hat verdeutlicht, dass das *Repräsentieren* und *Entdecken* von Strukturen eine herausragende Stärke von KI-Methoden ist.

Das Repräsentieren von strukturierten Daten, z.B. mithilfe formaler Ontologien, ebnet den Weg für eine Zusammenführung heterogener Daten in einem kohärenten semantischen Rahmen. Dadurch werden Möglichkeiten für eine logisch und semantisch fundierte Auswertung geschaffen, darunter auch die Konsistenzprüfung unübersichtlicher Datenbestände.

Das Entdecken von Strukturen durch KI-Methoden ist besonders dann von Vorteil, wenn Zusammenhänge durch menschliche Betrachter nicht erkannt werden können, sei es wegen einer zu großen Datenmenge oder wegen einer unübersehbaren Vielfalt von Einflussgrößen. Dazu gehören insbesondere die für Mobilität im Stadtverkehr relevanten Daten, deren komplexes Zusammenspiel bisher nur annähernd beherrscht wird. Beispiele sind Taxiwünsche in einer Großstadt, die durch Analyse und Koordinierung eine gleichzeitige Benutzung von gemeinsamen Taxis zulassen würde, oder die Bereitstellung von Zusatzfahrzeugen bei prognostizierten Engpässen im ÖPNV.

3.8. KI-SOFTWARE-WERKZEUGE

Anwendungen mit KI-Methoden können in aller Regel nur unter Verwendung dedizierter Software-Werkzeuge wirtschaftlich erstellt werden. Dabei spielen logikbasierte Werkzeuge für das Semantische Netz eine immer noch bedeutende Rolle, aber in zunehmender Zahl auch neuentwickelte Werkzeuge zur Analyse großer Datenbestände, insbesondere zur Anwendung von Deep Learning. Unterschiedliche Dienste werden häufig integriert in gemeinsamen Plattformen oder Paketen angeboten. Die folgenden Steckbriefe stützen sich auf aktuelle Web-Einträge für häufig verwendete KI-Software-Werkzeuge.

Caffe

Frei verfügbares Rahmenwerk für Deep Learning, ermöglicht Anwendungs-entwicklungen ohne Kodierung, erweiterbar, optimiert für schnelle Bildverarbeitung.

CATMA

CATMA (Computer Assisted Textual Markup and Analysis), ein frei verfügbares Werkzeug zur Textanalyse mithilfe von Annotationen und Markierungen. Ermöglicht Zusammenarbeit mehrerer Nutzer über das Web.

CLIPS

CLIPS (C-Language Integrated Production System), LISP-ähnliche Entwicklungsumgebung für regelbasierte Expertensysteme, umfasst Programmiersprache COOL mit objektorientierten, funktionalen und prozeduralen Möglichkeiten.

Cognitum

Vielseitiges Open Source Werkzeug für KI-Systeme. Unterstützt sowohl logikbasierte Inferenzen als auch Black-box-Inferenzen auf der Basis von KNN und Deep Learning. Ontologieeditor und Nutzerinteraktionen in kontrollierter natürlicher Sprache.

FaCT++

Experimentelles Inferenzsystem für Konsistenzprüfung und Schlussfolgerungen in großen Wissensbeständen, Repräsentation mit Beschreibungslogiken. Verwendet neuartige Verfahren zur Laufzeitoptimierung.

Hadoop

Freies, in Java geschriebenes Framework für skalierbare, verteilt arbeitende Software und große Datenmengen. Basiert auf dem MapReduce-Algorithmus von Google.

JESS

JESS (Java Expert System Shell), um Regelverarbeitung erweiterte Programmiersprache Java, geeignet zur Entwicklung von Expertensystemen und regelbasierter Wissensverarbeitung.

KARMA

Open Source Werkzeug zur semantischen Integration großer Datenmengen aus heterogenen Datenquellen (SQL, XML, JSON, CSV, Excel, AVRO, Web-Services). Erzeugt Linked Data für nutzergewählte Ontologien. Graphische Interaktion.

OpenRefine

Frei verfügbares Werkzeug zur Behandlung großer Datenmengen in verschiedenen Formaten. Transformation von Zellen, Anwendung von Filtern in Gestalt von regulären Ausdrücken, Analyse von Textfeldern, Erzeugung von Links zwischen Dateien.

Open Semantic Framework

Integrierte Plattform für Wissensmanagement. Überführt heterogene web-basierte Datenquellen in RDF-basierte Repräsentation mit gemeinsamer Ontologie. Bietet Annotations- und Markierungsdienste.

Prolog

Logikbasierte deklarative Programmiersprache, Programme bestehen aus Wissensbasis und Regeln. In zahlreichen Implementierungen frei verfügbar, häufig als Basis für komplexe KI-Systeme verwendet (z.B. Watson).

Protégé

Frei verfügbarer Open-Source Editor für Ontologien, Rahmensystem zur Entwicklung wissensbasierter Systeme, unterstützt OWL und andere Beschreibungslogiken.

R

Open Source Programmiersprache mit leistungsfähigen Funktionen für große Datenmengen und zahlreiche Anwendungsbereiche, insbesondere statistische Analyse und graphische Darstellungen. Optimiert für Berechnungsvorgänge mit Feldern und Matrizen. Anwendungspakete mit KI-Methoden, z.B. Klassifikation und Cluster-Analyse.

TensorFlow

Open-Source-Programmbibliothek, ursprünglich von Google entwickelt, zum Lernen für Sprach- und Bilderkennung.

Torch

Open-Source Programmbibliothek für maschinelles Lernen und statistische Analysen, Skriptsprache basiert auf Lua und C, für alle Plattformen geeignet.

Watson

Von IBM entwickeltes Programmsystem zur semantischen Suche in großen Textbeständen. Auswertung von natürlichsprachlichen Anfragen. Bausteine für Maschinelles Lernen, Inferenzen und Hypothesenbildung.

WordNet

Lexikalische Datenbasis für Wortschatz in englischer Sprache. Enthält wesentliche semantische Beziehungen (Synonyme, Antonyme, Oberbegriffe, Beispiele etc.), frei verfügbar mit Compiler.

4. INTERVIEWS UND TAGUNGEN

4.1. INTERVIEWS MIT STAKEHOLDERN

In den Interviews wurden gezielt Datenlieferanten und mögliche Endanwender in besonderen Schlüsselrollen oder Schnittstellenfunktionen aus dem Mobilitätsbereich angesprochen. Dazu gehören in erster Linie Einrichtungen, die Mobilitätsdienste zur Verfügung stellen, aber auch Behörden, die für Infrastruktur und Umweltaspekte zuständig sind. Zusätzlich wurden einige potenzielle Endanwender einbezogen. Die folgende Liste führt alle Interviewpartner auf.

- Deutsche Bahn AG
- Hamburger Hochbahn
- Verbund Deutsche Verkehrsbetriebe e.V.
- Hamburg Airport
- Hamburg Port Authority
- Behörde für Seeschifffahrt und Hydrographie
- Behörde für Wirtschaft, Verkehr und Innovationen
- Landesbetrieb für Straßen, Brücken und Gewässer
- Verkehrsleitzentrale Hamburg
- Behörde für Umwelt und Energie
- Bundesministerium für Verkehr und digitale Infrastruktur
- Landesamt für Geoinformation und Vermessung
- Signal-Iduna Versicherungskonzern
- Mecom GmbH
- Ströer KGaA

In den Interviews wurden häufig Probleme und Vorbehalte hinsichtlich der Bereitstellung von Datensätzen als Open Data angeführt. Ein wesentlicher Grund besteht darin, dass viele Daten von den Interviewpartnern als wirtschaftlich relevant eingestuft oder an anderer Stelle veredelt und kommerziell angeboten werden.

In den Hamburger Behörden werden Datensätze vielfach aufgrund des Hamburger Transparenzgesetzes veröffentlicht, wenn auch nicht kontinuierlich und automatisiert. Aus den Äußerungen über Veröffentlichungsvorbehalte und Datenschutzfragen der Interviewpartner kann man zudem einen Bedarf an akkreditierter Anonymisierung für Daten-Provider ableiten.

Interviewpartner, die Dienstleistungen aus dem Mobilitätssektor anbieten oder mit der Planung und Koordinierung im Verkehrswesen tätig sind, zeigten großes Interesse an der Simulation von Verkehrsverhalten, z.B. im Zusammenhang mit Baustellenplanung, Verkehrsprognosen und Optimierung von Fahrplänen. Hierfür müssen der gesamte Verkehr (Rad-, Fußgänger-, ÖPN-, ÖPF-, Automobilverkehr) sowie zusätzliche Einflussgrößen (z.B. Ferien, Wetter oder Veranstaltungen) einbezogen werden.

Vielen Befragten ist ein umfassendes Kennenlernen von Kundenbedürfnissen und Kundenverhalten wichtig, also nicht nur das Mobilitätsverhalten, sondern auch die damit verbundenen Anliegen. Man möchte z.B. zwischen Verkehrsströmen zu Arbeitsstellen, zu Veranstaltungen, zu Freizeitornten, zum Einkaufen, etc. unterscheiden. Hier gibt es natürlich Datenschutzprobleme, Methoden des Crowdsourcing sind möglicherweise geeignet.

4.2. TAGUNGEN UND WORKSHOPS

Mitglieder des ODAKI-Teams haben an einschlägigen Tagungen und Workshops teilgenommen und dabei teilweise auch das Projekt und seine Ziele präsentiert.

mFund-Workshop und Konferenz, in Berlin vom 01.08. - 02.08.2017

International Joint Conference on Artificial Intelligence, Melbourne, in Australien vom 17.08. - 27.08.2017

Co-Creation-Workshop INNOZ, in Berlin am 26.09.2017

KI-Konferenz, in Dortmund vom 26.09 - 29.09.2017

Open Data Science Conference, in London vom 13.10.-14.10.2018

ITS Hackathon DB, in Hamburg 20.10.-21.10.17

Mobility Hackathon Hochbahn, in Hamburg vom 22.09.-23.09.2017

Data Run Hackathon BMVI, in Berlin vom 02.03.-03.03.2018

Auftakt-Workshop des WIK zur mFund-Begleitforschung (Wissenschaftliches Institut für Infrastruktur & Kommunikationsdienste Bonn), in Bonn am 07.12.2017

Workshop zu mFund-Demonstratoren "Artificial Intelligence supported Flow Management" und "Data Driven Planning" INNOZ, in Berlin am 01.02.2018

Big Data & AI Summit, in Hanau vom 28.02. - 01.03.2018

5. PROJEKTSKIZZEN

5.1. TRAFFIC ALERT



PROJEKTIDEE

Laut dem Kraftfahrt Bundesamt lag der Fahrzeugbestand in Deutschland am 1. Januar 2017 bei 62,6 Millionen Kraftfahrzeugen, was einem Zuwachs von mehr als einer Million Kraftfahrzeugen im Vergleich zum Vorjahr entspricht⁴. Dabei bildeten Personenkraftwagen mit einem Anstieg um +1,6 Prozent und mit etwa 45,8 Millionen Einheiten den größten Anteil. Dieser Zuwachs stellt in Städten wachsende Herausforderungen für die Regelung des Verkehrsflusses. Dabei ist eine optimale Verkehrsführung nicht nur entscheidend für die VerkehrsteilnehmerInnen, um zügig zu ihren Zielen zu gelangen, sondern auch um z.B. den CO₂-Ausstoß und den Verkehrslärm zu verringern.

Die Verkehrsleitzentrale in Hamburg hat zurzeit Zugriff auf 1733 Ampelanlagen. Die MitarbeiterInnen können mithilfe von 82 Verkehrskameras den Stadtverkehr beobachten. Die Livebilder werden auf Monitore und eine 22 m² große Leinwand übertragen, auf der 48 Knotenpunkte oder stark befahrene Straßen zu sehen sind. Die MitarbeiterInnen können jedoch nicht alle 82 Kameras gleichzeitig einschalten bzw. beobachten, und fokussieren deshalb auf Bereiche, von denen sie aus Ihrer Erfahrung wissen, dass z.B. bei bestimmten Zeiten und Wetterlagen besondere Aufmerksamkeit gefordert ist. Dabei ist es unvermeidlich, dass kritische Situationen übersehen werden.

Zur Bewältigung der Monitoraufgaben für komplexe Verkehrssituationen können automatisierte Vorgänge einen bedeutenden Beitrag leisten. Mit TRAFFIC ALERT sollen Verkehrssituationen anhand von Bildinformationen automatisiert erkannt werden. Dadurch können die Monitoraufgaben für Menschen erleichtert werden, Maßnahmen zur Verkehrskontrolle können optimiert werden.



DATENQUELLEN

Sensordaten für kritische Verkehrsbereiche sind die primären Datenquellen für TRAFFIC ALERT. In Hamburg sind Kameradaten in der Verkehrsleitzentrale zusammengeführt, aber für rechnerbasierte Auswertung zurzeit nicht freigegeben, siehe Video-Verkehrsdaten im Abschnitt [Datenverzeichnisse]. Als bildgebende Verfahren sind neben herkömmlichen Videobildern auch Infrarotbilder geeignet.



VORGEHEN

Zur Objekterkennung und -klassifikation haben sich Neuronale Netze in den letzten Jahren hervorragend bewährt. Für den Verkehrsbereich sind die nötigen Voraussetzungen aufgrund einer großen Zahl von gut verfügbaren Lernbeispielen und erprobter Lernverfahren gut erfüllt. Objekterkennung ist zudem für autonomes Fahren und Fahrerassistenzsysteme ein aktuelles Entwicklungsgebiet. Für die Objekterkennung in der hier beschriebenen

Anwendung kann man deshalb voraussichtlich auf erprobte Verfahren zurückgreifen.

Ereigniserkennung

Um kritische Ereignisse, wie z.B. Blockaden von Kreuzungen oder Unfälle erkennen zu können, können KI-Methoden zur Szenenanalyse herangezogen werden. Die hierfür erforderliche Technologie ist in Forschungsprojekten erprobt, in der Praxis allerdings noch nicht verbreitet eingesetzt worden. Bei der Überwachung von Kreuzungen sind die Randbedingungen für Ereigniserkennung allerdings relativ günstig, weil die Bilder aus konstanter Perspektive erzeugt und Ereignismodelle klar formuliert werden können.

Die Abbildung illustriert eine einfache Kreuzungssituation, in der eine Blockade durch den Einsatz eines Rettungswagens entstanden ist. Die Ereigniserkennung würde die auf Fahrspuren zum Stehen gekommenen und sich blockierenden Fahrzeuge als ein "Blockadeereignis" erkennen und ggf. erforderliche Maßnahmen anstoßen.



Abbildung 4: Objekterkennung im Straßenverkehr

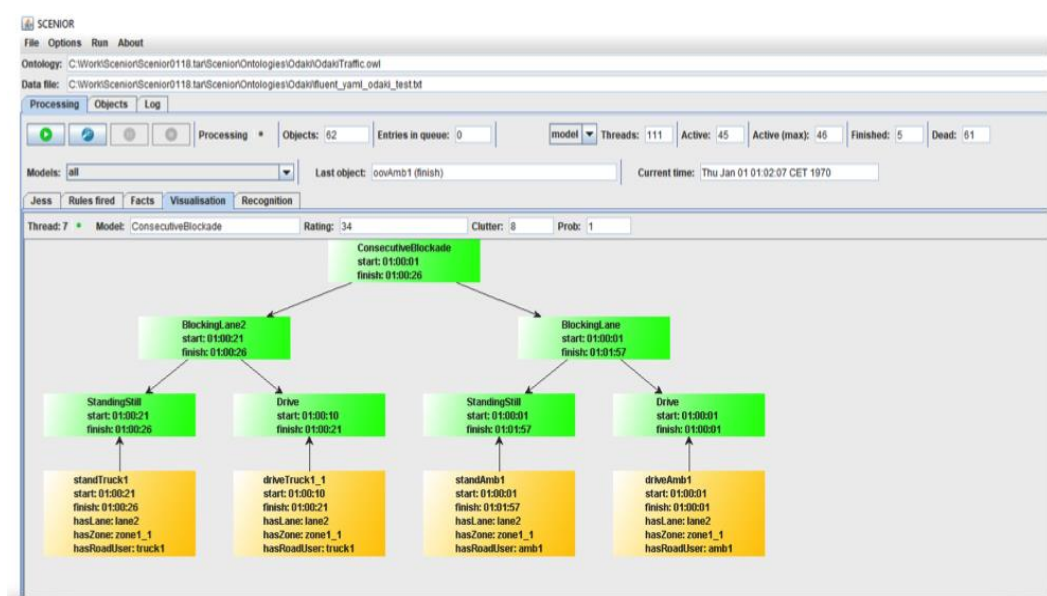


Abbildung 5: Szeneninterpretation mit SCENIOR

Die Ereigniserkennung von Kreuzungssituationen wurde im Rahmen von ODAKI als Demonstrator implementiert. Dazu konnte das bei HITeC entwickelte Software-System SCENIOR (Scene Interpretation by Ontology-based Rules) verwendet werden. SCENIOR basiert auf einer Ontologie, in der die für eine Anwendung relevanten Ereignisse als sog. kompositionale Modelle beschrieben werden. Dies sind strukturierte Datenstrukturen, die sich in mehreren hierarchischen Ebenen aus Komponenten zusammensetzen. Daraus leitet SCENIOR automatisch Erkennungsregeln ab und setzt sie für das Analysieren konkreter Szenen ein. Abbildung 5 zeigt, wie SCENIOR vier individuelle Fahrzeugbewegungen (braune Felder) als Teile der komplexen Verkehrssituation "ConsecutiveBlockade" erkennt.

Als Eingabedaten benötigt SCENIOR die Bewegungsdaten einzelner Fahrzeuge, die aus Sensoraufzeichnungen mit Methoden der Objekterkennung und Objektverfolgung gewonnen werden können.



TECHNOLOGIEREIFEGRAD (TRL)

TRL 4: Versuchsaufbau im Labor



WEITERE ANWENDUNGSMÖGLICHKEITEN

Automatisierte Ereigniserkennung im Straßenverkehr kann in verschiedener Weise ausgenutzt werden. Oben stand die Verwendung in einer Verkehrsleitzentrale im Vordergrund. Dort könnte der Abdeckungsgrad von kritischen Bereichen im innerstädtischen Verkehr erhöht werden, gleichzeitig könnten MitarbeiterInnen entlastet werden.

Ein automatischer Traffic Alert wird für zukünftige Szenarien mit autonomen Fahrzeugen eine noch größere Bedeutung haben, etwa bei der automatisierten Routenplanung. Wenn z.B. autonome Taxis termingenau zu ihrem Bestimmungsort kommen sollen, müssen sie über Verzögerungen oder Blockaden automatisch informiert werden.

Ein weiterer Anwendungsbereich ist die Verkehrsplanung. Durch Traffic Alert können wichtige statistische Informationen zu kritischen Kreuzungen oder Straßenabschnitten gesammelt werden. Dadurch können z.B. Entscheidungen über notwendige straßenbauliche Maßnahmen abgesichert werden.

5.2. BIKE DISTRIBUTOR



PROJEKTIDEE

Wegen der übermäßigen Benutzung von Privatautos sind Umweltbelastungen, wie Lärm und Feinstaubemissionen, ungelöste Probleme in Großstädten. Um damit nachhaltig umzugehen, müssen attraktive Transportalternativen angeboten werden. Sharing-Dienste wie „Stadtrad“ können dabei eine tragende Rolle spielen. Damit dieser Dienst für die StadtbewohnerInnen attraktiv ist, müssen Stadträder zuverlässig und allorts zur Verfügung stehen. In Hamburg ist dieses Ziel noch nicht optimal realisiert: Vielfach fehlen Stadträder an einzelnen Stationen, während sie sich an anderen Stationen häufen. Grund ist offenbar eine suboptimale Verteilung, bei der orts- und zeitabhängiger Bedarf falsch eingeschätzt wird.

Mit BIKE DISTRIBUTOR soll es möglich werden, Engpässe an Stadtradstationen weitgehend zu vermeiden. Dies kann erreicht werden, wenn die Bedarfsstatistiken der Stadtradstationen mit relevanten Einflussgrößen korreliert werden, z.B. Tageszeiten, Wochentagen, Wetterdaten, besonderen lokalen Ereignissen etc. Daraus können Bedarfsvorhersagen abgeleitet werden, die zu einer besseren Verteilung von Stadträdern auf die Stationen führen und zu einer Vermeidung von Engpässen beitragen.



DATENQUELLEN

Für die Realisierung vom BIKE DISTRIBUTOR war Zugriff auf die folgenden Datenquellen erforderlich, siehe Abschnitt [Datenverzeichnisse]:

- Geo-Daten der Stadtradstationen
- Geo-Daten des Straßennetzes
- Aktuell verfügbare Stadträder an jeder Station, erneuert alle 10 min
- Checkout- und Checkin-Daten für individuelle Stadträder an jeder Station
- Wetterdaten (Temperatur, Niederschlag, Wind, Luftdruck)
- Veranstaltungskalender mit Zeiten und Geo-Daten (Kultur, Sport, Festivals)



VORGEHEN

Für die erfassten Daten wird ein probabilistisches Modell in Gestalt eines Bayes-Netzes entwickelt. Es modelliert das Ausleihverhalten an einzelnen Stationen als Effekt von vermuteten Einflussgrößen. Abbildung 6 illustriert die zu erwartende Bayes-Netz-Struktur.

Die dafür erforderliche Statistik erfasst als Ereignisse die Summe der stündlich an jeder Station erfolgten Checkouts und Checkins. Die probabilistische Modellierung erfordert eine geeignete Diskretisierung der Wertebereiche aller Variablen. Dabei muss die Granularität genügend fein sein, um die Einflüsse hinreichend genau zu modellieren, aber genügend grob, um die Dimensionalität der Statistik in Grenzen zu halten.

Die Struktur des aus der Statistik gewonnen Bayes-Netzes kann weitgehend aus den physikalischen Zusammenhängen abgeleitet werden. Die mittleren Knoten repräsentieren die integrierten ortsunabhängigen bzw. ortsabhängigen

Einflüsse. Diese Knoten sind verdeckte Variable ("hidden variables"), deren Verteilungen aus den bekannten statistischen Werten mit besonderen Inferenzverfahren gewonnen werden können.

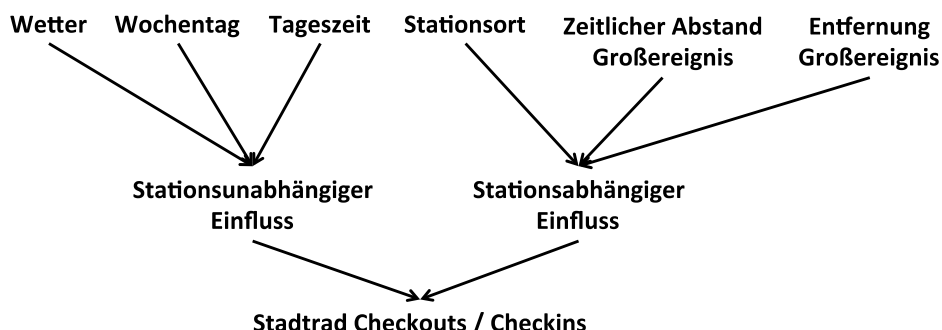


Abbildung 6: Struktur eines Bayes-Netzes zur Vorhersage von Stadtradbenutzung

Der wesentliche Nutzen des Bayes-Netzes besteht darin, Vorhersagen zum Ausleihverhalten an individuellen Stationen zu machen und die Verteilung von Stadträdern entsprechend vorzunehmen. Dazu werden die für die Vorhersage bekannten Kontextgrößen und die zu betrachtenden Stadtradstationen eingegeben, und das erwartete Checkout bzw. Checkin-Verhalten abgefragt.

Als Alternative zur Modellierung durch ein Bayes-Netz kann auch ein Neuronales Netz verwendet werden, das die Werte der Statistik als Lernbeispiele einsetzt. Das NN könnte z.B. Wertekonstellationen erlernen, die typischerweise zu einem Engpass an einer Station führen. Im Gegensatz zum Bayes-Netz ist dieser Ansatz jedoch wesentlich intransparenter, und seine Aussagen können nicht ohne Weiteres als "bestmögliche Vorhersagen" gedeutet werden.

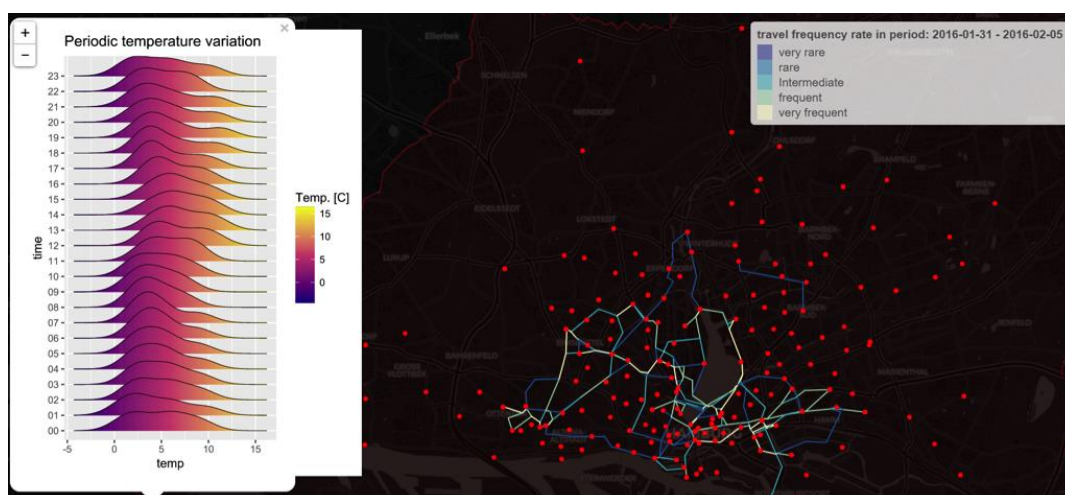


Abbildung 7: Visualisierung der häufigsten Stadtradrouten basierend auf Open Data der deutschen Bahn und Wetterdaten des Deutschen Wetterdienstes



TECHNOLOGIEREIFEGRAD (TRL)

TRL 3: Nachweis der Funktionstüchtigkeit einer Technologie (5-13 Jahre)



WEITERE ANWENDUNGSMÖGLICHKEITEN

Das Bayes-Netz kann zusätzlich zur Untersuchung und Prognose von Einflüssen verwendet werden, z.B. durch Vorgabe fiktiver Wettersituationen oder Großveranstaltungen.

Durch Integration neugewonnener Daten kann das Modell, wenn erforderlich, jederzeit aktualisiert werden.

5.3. HISTOURY



PROJEKTIDEE

Hamburg lockt jährlich ca. 14 Mio. Touristen zu einem Besuch in die Hafenstadt. Viele verwenden das attraktive Stadtradangebot der DB, um Stadt und Umgebung zu erkunden. Dazu kommen jährlich ca. 10000 neue Studierende, von denen auch viele mit dem Fahrrad unterwegs sind und dabei die Hansestadt kennenlernen möchten. Natürlich gibt es Informationen in Stadtführern und im Web, mit denen vorwiegend aktuelle Attraktionen beschrieben werden. Hinweise auf historische Orte und Sehenswürdigkeiten, illustriert mit historischem Bildmaterial, stehen jedoch für interessierte Radbummler kaum zur Verfügung.

Hier soll die App HISTOURY helfen. Sie bietet Radfahrern Unterstützung bei der Routenplanung mit Hinweisen auf historische Sehenswürdigkeiten, die entlang einer Route zu erreichen sind. Außerdem macht sie während einer Fahrt auf interessante Orte in der Nähe aufmerksam und lädt zu kleinen Abstechern ein. Sehenswürdigkeiten werden mit Bild und erläuterndem Text auf der App dargestellt, Routeninformationen werden in einem auf der App dargestellten Stadtplan markiert.



DATENQUELLEN

Für die Realisierung von HISTOURY ist Zugriff auf die folgenden Datenquellen erforderlich, siehe Abschnitt [Datenverzeichnisse]:

- Historische Fotos – eFoto Hamburg: ca. 8000 historische Fotos, mit Schlüsselwörtern, erläuterndem Text und Geodaten der Kulturbehörde Hamburg
- Hamburger Straßennetz
- Spezielle Fahrradrouten
- Stationen des Bike Sharing-Anbieters Stadtrad



VORGEHEN

Das zentrale Ziel der App besteht darin, Fahrradfahrer auf interessante historische Sehenswürdigkeiten entlang einer Fahrradrouten in adäquater Form aufmerksam zu machen. Die Bestimmung der in Frage kommenden Sehenswürdigkeiten ist durch Vergleich der GPS-Daten des Fahrers mit dem Geodaten der Sehenswürdigkeiten relativ einfach zu erreichen. Für die Benachrichtigung des Fahrers während der Fahrt kommen akustische oder taktile Signale in Frage, ähnlich wie bei Kommunikation.

KI-Methoden spielen bei einer Fokussierung der Ziele auf spezifische Benutzerinteressen eine besondere Rolle. Z.B. könnte sich ein Benutzer vorwiegend für historische Gasthäuser interessieren. Dazu müssten die Angebote nach Begriffskategorien inkl. einer Oberbegriffshierarchie geordnet werden. Wünschenswert wäre auch eine Möglichkeit zur Formulierung von Einschränkungen, z.B. "vor dem 1. Weltkrieg".

Die HISTOURY-App konnte als demonstrierbarer Prototyp realisiert werden.

Dazu trugen Studierende einer Lehrveranstaltung des Fachbereichs Informatik entscheidend bei, denen HITeC als "Auftraggeber" die Anforderungen für diese App vorgeben konnte. Die Arbeiten wurden von einer 7-köpfigen Gruppe in den Monaten November 2017 bis Februar 2018 durchgeführt, das Ergebnis wurde im Januar 2018 erfolgreich demonstriert. [Rana et al. 2017]

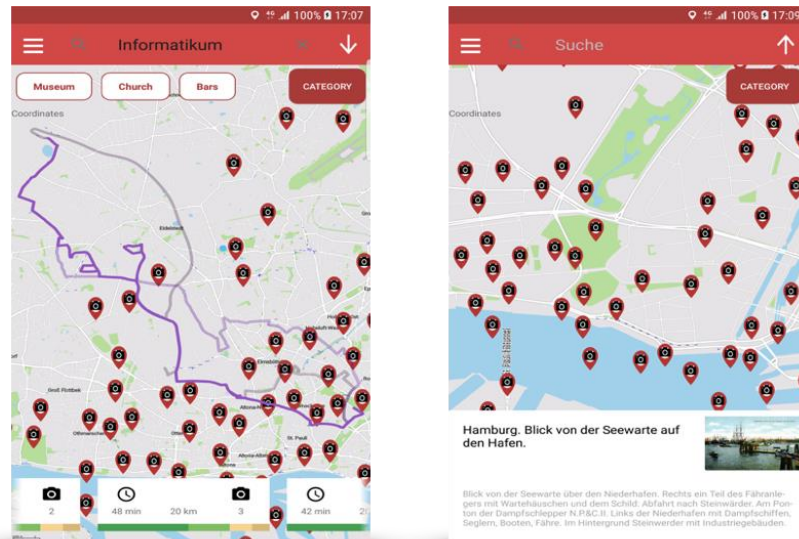


Abbildung 8: HISTOURY Demonstrator



TECHNOLOGIEREIFEGRAD (TRL)

TRL 6: Prototyp in Einsatzumgebung



WEITERE ANWENDUNGSMÖGLICHKEITEN

Die App kann neben ihrer Hauptfunktion, auf Sehenswürdigkeiten entlang von Fahrradtouren aufmerksam zu machen, auch diverse Zusatzfunktionen anbieten, die teilweise auch bereits realisiert wurden.

Routenplanung zum Erreichen von spezifischen Zielen

Hier können Interessensbereiche vorgegeben werden, z.B. historische Gasthäuser (s.o.) oder Marktplätze. Die App entwirft dazu eine Route, mit der innerhalb einer vorgegebenen Zeit möglichst viele dieser Ziele erreicht werden können. Zur Realisierung kommen optimierende KI-Suchverfahren zum Einsatz (A*-Algorithmus). Um eine Auswahl mit frei wählbaren Schlüsselworten zu ermöglichen, kann eine semantische Kategorisierung mithilfe einer Ontologie eingesetzt werden.

Aufzeichnen und Weitergabe von empfohlenen Routen

Für einen Stadtfremden kann es interessant sein, die bei einer Erkundungstour gefolgte Route nachträglich auf einem Stadtplan betrachten zu können. Dazu müssen die GPS-Koordinaten während einer Tour zusammen mit Zeitstempeln gespeichert und in einer persönlichen Tourdatenbank abgelegt werden. Es liegt, nahe, Touren dann auch als Empfehlungen an Bekannte weitergeben zu können. Diese müssten dann natürlich auch mit der HISTOURY-App ausgestattet sein.

5.4. 3D STREET MATCH



PROJEKTIDEE

Täglich produzieren Menschen unterschiedliche Emissionen, die sich auf die Luftqualität auswirken und gesundheitliche Schäden verursachen können. So steht laut einer Studie des Umweltbundesamtes die Belastung mit Stickstoffdioxiden im „Zusammenhang mit Krankheiten, wie Diabetes mellitus, Bluthochdruck, Schlaganfall, der chronisch obstruktiven Lungenerkrankung (COPD) und Asthma.“⁵ Dieser Problematik hat sich die EU angenommen und Luftqualitätsrichtlinien entwickelt, die u.a. regeln, wo Messstellen zu betreiben sind, welche Luftverunreinigungen mit welchen Methoden und welcher zeitlichen Auflösung zu messen sind, sowie welche Grenz- oder Zielwerte einzuhalten sind.⁶

Gemäß diesen Richtlinien überwacht Hamburg die Luftqualität. Nach Aussage der Behörde für Umwelt und Energie (BUE) sei jedoch die Einhaltung der Richtlinien ein komplexer und kostenintensiver Vorgang, weshalb in Hamburg nur 15 Stationen betrieben werden. Es können dadurch punktuelle Aussagen getroffen werden, aber keine flächendeckenden.

Mit 3D STREET MATCH soll es jetzt möglich werden, auch an Orten ohne Messstationen Aussagen über die Luftqualität zu machen. Dass besonders in Städten die Luftqualität regelmäßig Grenzwerte überschreitet, liegt hauptsächlich am starken Individualverkehr, wird aber wesentlich dadurch begünstigt, dass Straßenzüge oft dicht und hoch bebaut sind, die Luft dadurch nicht zirkulieren kann und die Emissionen in den Straßen festgehalten werden. 3D STREET MATCH soll daher automatisiert erkennen, welche Straßenzüge auf Grund von Straßenbreite, Bebauung, Windrichtung, und Verkehrsdichte mit der Umgebung einer Messstation vergleichbar sind. Dadurch kann die Belastung von Straßenzügen auch ohne unmittelbar in der Nähe befindliche Messstationen geschätzt werden.



DATENQUELLEN

Für die Realisierung von 3D STREET MATCH ist Zugriff auf die folgenden Datenquellen einer Stadt erforderlich, siehe Abschnitt [Datenverzeichnisse]:

- Straßenzüge der Stadt
- 3D Bebauungsprofil
- Positionen der Messstellen
- Wetterdaten an den Messstellen (Windrichtung, Windstärke, Temperatur)
- Luftbelastung an den Messstellen (Feinstaub, NOX, CO2)
- Aktuelle Verkehrsdichte in Straßenzügen



VORGEHEN

Die zentrale Aufgabe von 3D STREET MATCH ist ein Vergleich zwischen den

⁵ <https://www.umweltbundesamt.de/no2-krankheitslasten>

⁶ https://www.umweltbundesamt.de/sites/default/files/medien/378/publikationen/das_luftmessnetz_des_umweltbundesamtes_bf_0.pdf

Bebauungsprofilen an Messstellen und denen an anderen Positionen innerhalb einer Stadt. Hierfür eignen sich mehrere KI-Methoden:

(i) Mustererkennung

Die Situation an einer Messstelle wird als Merkmalsvektor beschrieben und im mehrdimensionalen Merkmalsraum mit den korrespondierenden Merkmalsvektoren an anderen Orten verglichen. Aus dem Abstand im Merkmalsraum kann dann abgeleitet werden, ob dort ähnliche Belastungswerte wie an der Messstelle zu erwarten sind. Eine wohlüberlegte Definition der Merkmale kann die Treffsicherheit von MULTICHECK wesentlich beeinflussen, offensichtlich sind nicht alle geometrischen Merkmale der Bebauungsprofile gleichermaßen relevant. Wichtig ist z.B. ein Maß für die Belüftung eines Straßenzuges bei vorgegebenen Windverhältnissen. Die Bestimmung geeigneter Merkmale erfordert fachlich fundierte Überlegungen und ggf. auch Experimente.




Abbildung 9: 3D Straßenzug mit Merkmalsvektor

(ii) Gelernter Klassifikator

Eine Alternative zu Mustererkennung ist das Erlernen geeigneter Merkmale anhand von Lernbeispielen. Hierzu müssten zahlreiche Bebauungs- und Wettersituationen mit ihren jeweiligen Belastungsdaten in ein KI-Lernverfahren eingespeist werden. Als Ergebnis stände ein Klassifikator zur Verfügung, der in Abhängigkeit von Bebauung, Wetter und Verkehrsverhältnissen die zu erwartende Schadstoffbelastung ausgibt. Der Vorteil dieses Ansatzes besteht darin, dass das Lernverfahren selbsttätig relevante Merkmale ermittelt, eine durch Fachleute bestimmte Merkmalsauswahl kann also entfallen. Andererseits stellt die Beschaffung von hinreichend vielen Lernbeispielen (wohl weit über eintausend) eine beträchtliche Hürde dar.

(iii) Analogische Inferenz

Die Beurteilung einer unbekanntem Situation durch Übertragen von Erkenntnissen aus bekannten Situationen kann auch als Analogische Inferenz modelliert werden, in Anlehnung an Analogieschlüsse bei Menschen. Dazu werden Situationen mit den Mitteln semantischer Wissensrepräsentation als Relationalstrukturen dargestellt, in denen Abstraktionen, Verallgemeinerungen und Spezialisierungen durchgeführt werden können. Bei einem Vergleich wird geprüft, inwieweit die unbekanntem Situation von der bekannten subsumiert wird, also durch analogische Inferenz mit abgedeckt wird. Das Verfahren unterscheidet sich von merkmalsbasiertem Vergleich durch die Möglichkeit,

logisch fundierte Inferenzen zu verwenden, erfordert allerdings eine differenzierte Wissensrepräsentation.



TECHNOLOGIEREIFEGRAD (TRL)

Für alle oben genannten Realisierungsmöglichkeiten gilt
TRL 3: Nachweis der Funktionstüchtigkeit einer Technologie (5-13 Jahre)



WEITERE ANWENDUNGSMÖGLICHKEITEN

Die Übertragung von Messwerten auf Orte mit vergleichbaren Bebauungsverhältnissen kann auch für die Bebauungsplanung eingesetzt werden. Dadurch könnte vor Realisierung einer Bebauung geprüft werden, ob in bestimmten Wetterlagen möglicherweise eine besondere Schadstoffbelastung entstehen kann. Zur Abhilfe könnten Durchlüftungskorridore quer zu Straßenschluchten vorgesehen werden.

5.5. CITY VISION



PROJEKTIDEE

Laut Online-Portal „Statista“ leben heute mehr als 75% der deutschen Bevölkerung in Städten. Bis 2050 wird ein Zuwachs auf 83% prognostiziert. Schon heute ist urbaner Wohnraum knapp und die Bewohnerdichte sorgt für vielfältige Umweltbelastungen, wie Verkehrsbelastung, Lärm, Feinstaub, Müll etc.. Damit bei dieser rasanten Urbanisierung und den immer komplexer werdenden Wirkungsketten nachhaltige Entscheidungen für die Stadtentwicklung getroffen werden können, werden Planungshilfen benötigt.

CITY VISION fokussiert auf Mobilitätsaspekte in der Stadtplanung und versucht dazu, eine möglichst umfassende Zahl von Einflussgrößen mit einzubeziehen. Das Spektrum möglicher Anwendungen, z.B. für eine dynamische Stadt wie Hamburg, ist vielfältig. Wie kann der geplante Elbtower verkehrstechnisch integriert werden? Welche Folgen hat eine weiträumige Absperrung des Hafengeburtstags, bei gutem oder bei schlechtem Wetter? Welchen Einfluss wird die Sperrung einer strategischen Straßenverbindung auf das Fahrgastaufkommen im ÖPNV oder auf den Fahrradverkehr haben?

Zur Visualisierung derartiger Planungsszenarien versucht CITY VISION, vergleichbare Szenarien aus vorhandenen Datenbeständen derselben Stadt zu ermitteln und an die Fragestellungen bei geplanten Szenarien anzupassen. Dabei ist zu erwarten, dass die Leistungsfähigkeit des Systems durch Erweiterung der Datenbestände stetig gesteigert werden kann, sowohl hinsichtlich der Präzision von Aussagen als auch der Breite von Anwendungsmöglichkeiten. Die Planungsszenarien sollen durch menschliche Planungsexperten parametrierbar sein und graphisch anschaulich aufbereitet werden.



DATENQUELLEN

Für die Realisierung von CITY VISION ist Zugriff auf die folgenden Datenquellen einer Stadt erforderlich, siehe Abschnitt [Datenverzeichnisse]:

- Planungsdaten zur Stadtentwicklung
- Baustellenplanung
- Bewohnerstatistiken
- Verkehrsdichten im Straßenverkehr
- Personenströme
- ÖPNV-Benutzung
- Bebauungsprofile
- Parkräume
- Veranstaltungsdaten
- Wetterdaten



VORGEHEN

CITY VISION ist als ein hybrides System konzipiert, in dem die untere Systemschicht (die Statistikkomponente) konkrete Situationen und Vorgänge aus den Datenbeständen bereitstellt, und die darüber liegende Systemschicht

(die Reasoning-Komponente) Verallgemeinerungen, Extrapolationen und Anpassungen an die betrachtete Planungssituation durchführt. Beide Komponenten erhalten einen gemeinsamen ontologischen Rahmen, mit dem die Integration heterogener Datenquellen in der Statistikkomponente, sowie die Anwendungen von Regeln und Schlussfolgerungen in der Reasoning-Komponente ermöglicht wird.



TECHNOLOGIEREIFEGRAD (TRL)

TRL 2: Beschreibung der Anwendung einer Technologie



WEITERE ANWENDUNGSMÖGLICHKEITEN

CITY VISION ist eine Projektidee, die sowohl durch Einbeziehen weiterer Datenbestände ausgebaut, als auch durch Fokussierung auf bestimmte Planungsaufgaben spezialisiert werden kann. Zum Beispiel könnten die in der Vergangenheit festgestellten Effekte von zusätzlichen Verkehrsampeln für Planungsszenarien ausgewertet werden. Oder man könnte CITY VISION auf Baustellenplanung spezialisieren. In diesem Sinn kann CITY VISION als Projektrahmen mit weitreichendem Potenzial angesehen werden.

5.6. PERSON STREAM



PROJEKTIDEE

Die Attraktivität und bedarfsgerechte Ausrichtung des öffentlichen Verkehrs ist ein ausschlaggebender Faktor für eine geringere Nutzung von Privatautos und die Reduktion der damit verbundenen Verkehrsemissionen. Um den öffentlichen Verkehr von morgen attraktiv und nachhaltig zu gestalten, ist es entscheidend, über Kenntnisse von Zielen und Bedürfnissen der Fahrgäste zu verfügen. Damit können Streckenverbindungen, Wartezeiten und Transportkapazitäten des öffentlichen Verkehrs optimiert, neue Verbindungen und Haltestellen konzipiert und Überangebote reduziert werden.

Auch die Hochbahn in Hamburg möchte ihre Fahrgäste besser kennenlernen, um nutzergerecht planen zu können. Dazu werden direkte Kundenbefragungen in den Fahrzeugen durchgeführt, diese sind aber sehr aufwendig und haben nur Stichprobencharakter. Neben der Optimierung der Fahrangebote ist die Hochbahn auch daran interessiert zu erfahren, welche Fahrgastströme innerhalb der Bahnhöfen zu bewältigen sind.

Mit dem Projekt PERSON STREAM sollen Bewegungsdaten von Personen erfasst, analysiert und anschaulich präsentiert werden. Hierfür sollen die Mobilfunkdaten von Fahrgästen genutzt werden, die über Telefonanbieter anonymisiert und aggregiert zu beziehen sind. Auch bieten Hotspots an Hochbahnstationen die Möglichkeit, Personenbewegungen zu erfassen. Aus der Analyse und Aufbereitung der Daten, sowie ihrer Korrelation mit weiteren Datenbeständen, können Einsichten über Zusammenhänge zwischen Mobilitätsverhalten und begleitenden Einflussgrößen gewonnen werden.



DATENQUELLEN

Für die Realisierung von PERSON STREAM ist Zugriff auf die folgenden Datenquellen erforderlich, siehe Abschnitt [Datenverzeichnisse]:

- Anonymisierte und aggregierte Mobilfunkdaten für Bewegungsdaten
- Geodaten der Funkzellen (Mobilfunkzellen)
- Bewohnerstatistiken
- Stadtplan
- Verkehrsverbindungen
- Veranstaltungsdaten
- Wetterdaten



VORGEHEN

PERSON STREAM umfasst zwei Komponenten: Eine Clustering-Komponente, mit der häufige Muster in Mobilitätsdaten ermittelt werden, und eine Korrelationskomponente, die Zusammenhänge mit potenziellen Einflussgrößen aufdeckt. Für die Cluster-Analyse stehen verschiedene KI-Methoden zur Verfügung, insbesondere K-Means oder NN-basierte Verfahren. Als Ergebnis werden Bewegungsmuster erwartet, die dann durch Korrelation mit Kontextdaten z.B. als Berufsverkehr, Einkaufstour oder Veranstaltungsbesuch

gedeutet werden können.



TECHNOLOGIEREIFEGRAD (TRL)

TRL 3: Nachweis der Funktionstüchtigkeit einer Technologie (5-13 Jahre)



WEITERE ANWENDUNGSMÖGLICHKEITEN

Bewegungsmuster von Personen können durch Korrelation mit den zugehörigen Personenprofilen (Altersgruppen, Familienstatus, Migrationshintergrund etc.) für verschiedenste Zwecke interessant sein. Zum Beispiel können Warenangebote oder Werbung gezielter auf die Klientel eines Bewegungsbereiches eingestellt werden.

Eine ähnliche Anwendung kann für Passagiere innerhalb eines Flughafens realisiert werden. Hier könnten Passagierströme z.B. durch die zahlreichen Video-Kameras erfasst und zahlenmäßig ausgewertet werden. Durch Korrelation mit den aktuellen Flugdaten sowie Einkaufsaktivitäten könnten Warenangebote und Werbung optimiert werden.

5.7. MY WAY



PROJEKTIDEE

In einer anspruchsvollen Gesellschaft, wie unserer, ist es relevant, nicht nur schnell von einem Ort zum anderem zu kommen, sondern dabei auch effizient zu sein. Je nach Lebenssituation wollen wir neben unserer Arbeit noch Kinder wegbringen und abholen, Einkaufen, Sport treiben, Freunde treffen usw. Um all diesen Ansprüchen gerecht zu werden, ist es wünschenswert, unsere Wegezeiten auf ein Minimum zu reduzieren.

Mit MY WAY kann die Nutzerin eine individuelle Route zusammenstellen, die sie schnell vom Start zum Ziel bringt und auf dem Weg alle Erledigungen tätigen lässt. Im Vergleich zu bisherigen Routenplanern soll MY WAY verschiedene Transportmittel kombinieren, wie z.B. die Nutzung des Stadtrads, ÖPNV oder Fußwege, und Zwischenziele einbeziehen. Darüber hinaus soll die Nutzerin zeitliche Vorgaben machen dürfen, also z.B. "späteste Ankunft" oder "maximale Dauer".



DATENQUELLEN

Für die Realisierung von MY WAY ist Zugriff auf die folgenden Datenquellen erforderlich, siehe Abschnitt [Datenverzeichnisse]:

- Stadtplan
- ÖPNV-Verbindungen
- Fahrradwege
- Fußwege
- Häufige individuelle Ziele



VORGEHEN

Der erste Schritt zur Realisierung ist - wie bei fast allen Projekten - die semantische Integration der zu berücksichtigenden Datenquellen. Hier spielen die individuellen Ziele eine besondere Rolle, die Daten müssen von der Benutzerin leicht eingegeben und auch verändert werden können. Um eine effiziente Routenplanung zu erreichen, müssen zwei erprobte KI-Methoden kombiniert werden, (i) effiziente Suchverfahren (A*-Algorithmus) und Beschränkungssysteme (Constraint Solving). Dies erfordert professionelle Programmierung.



TECHNOLOGIEREIFEGRAD (TRL)

TRL 3: Nachweis der Funktionstüchtigkeit einer Technologie (5-13 Jahre)



WEITERE ANWENDUNGSMÖGLICHKEITEN

Routenplanung unter Berücksichtigung von zusätzlichen Bedingungen kann auch für kommerzielle Botendienste, Lieferservices, etc. eingerichtet werden. Hier können sich KI-Methoden als besonders nützlich erweisen, da sie die Übertragung zwischen verschiedenen Anwendungsdomänen erleichtern.

5.8. SMART MAINTENANCE



PROJEKTIDEE

Ein wichtiger Kostenfaktor für Verkehrsbetriebe ist die Wartung der Verkehrsmittel, von Fahrzeugen und ihren Komponenten bis hin zu Fahrtreppen in Bahnhöfen. Wartung erfolgt heute meist in festgelegten Intervallen oder aus Anlass von Störungen. Als Alternative zu den festen Wartungsintervallen gibt es in modernen Anlagen seit einigen Jahren ein neues Konzept: vorhersehende Wartung (Preventive Maintenance). Dabei wird versucht, die Wartung komponentenweise an den tatsächlichen Bedarf anzupassen. Eine entscheidende Voraussetzung sind Sensoren an den vom Betrieb betroffenen Komponenten, die über Abnutzung und Wartungsbedarf informieren. Auf der Basis der Messwerte kann erkannt werden, ob eine Störung droht und Wartungsarbeiten erforderlich sind.

Die Vorteile von vorhersehender Wartung liegen auf der Hand: Wartungsarbeiten werden an den Bedarf angepasst, überflüssige Kosten können vermieden werden, und drohende Störungen werden vor ihrem Auftreten erkannt.

Zur Realisierung dieses Konzeptes muss die Vision eines "Internet-der-Dinge" (Internet-of-Things, IoT) Wirklichkeit werden. Im IoT werden Dinge (wenn erforderlich) als Agenten ausgerüstet. Sie erkennen ihren Zustand, können miteinander kommunizieren und von sich aus intelligente Entscheidungen treffen. Das IoT ist erst in wenigen experimentellen Anlagen realisiert. Wenn es aber in Verkehrsbetrieben eingesetzt wird, kann man es als eine moderne und umfassende Form von Open Data betrachten: Alle Dinge eines IoT geben ihre Daten offen ab (wenn auch nur an ein Intranet).



DATENQUELLEN

Komponenten von Verkehrsmitteln mit Wartungsbedarf, realisiert als IoT. Eine Kommunikationszentrale zeichnet den Datenstrom von Zustandsmeldungen (eine Form von Big Data) kontinuierlich auf.



VORGEHEN

Ein System für vorhersehende Wartung muss zwei Komponenten besitzen: Eine Lernkomponente, mit der störungsträchtige Situationen in den Zustandsmeldungen der Verkehrsmittel gelernt werden. Dies kann mit einem Neuronalen Netz (NN) geschehen, überwacht durch menschliche Experten. Bei gleichbleibender technischer Ausstattung der Verkehrsmittel ist die Lernphase nur einmal durchzuführen. Alternative Verfahren zum Erlernen von Klassifikatoren kommen ebenfalls in Frage.

Die zweite Komponente ist ein Mustererkennungssystem, das gelernte Wartungssituationen in den Big Data des IoT erkennt. Hierzu kann der in der Lernphase gewonnene Klassifikator verwendet werden. Zusätzlich kann auch Anomalieerkennung eingesetzt werden, etwa um bisher unbekannte störungsträchtige Situationen rechtzeitig zu erkennen. Für Anomalieerkennung eignen sich auch NN, mit denen Normalverhalten gelernt worden ist.



TECHNOLOGIEREIFEGRAD (TRL)

Sensorik und IoT:

TRL 2: Beschreibung der Anwendung einer Technologie

Vorhersehende Wartung und Anomalieerkennung:

TRL 3: Nachweis der Funktionstüchtigkeit einer Technologie (5-13 Jahre)



WEITERE ANWENDUNGSMÖGLICHKEITEN

Die oben beschriebene Technologie zur vorhersehenden Wartung ist natürlich nicht nur bei Verkehrsmitteln anwendbar, sondern bei vielen technischen Anlagen mit kostenintensivem Wartungsbedarf, z.B. Kraftwerksturbinen.

Eine Anomalieerkennung kann auch als eigenständige Funktion verwendet werden, unabhängig vom Wartungsmanagement.

5.9. REPORT ANALYSIS



PROJEKTIDEE

Im Mobilitätsbereich gibt es vielfach Vorfälle, bei denen textuelle Beschreibungen erzeugt werden, z.B. Unfallberichte, Schadensfälle, Anzeigen. Durch Analyse dieser Berichte können möglicherweise interessante Einsichten gewonnen werden. Z.B. können wiederkehrende Begleitumstände von Unfällen ermittelt werden, etwa ungünstige Straßenverhältnisse, schlechte Sicht, Korrelation mit Feiertagen.

Existierende Statistiken bieten für derartige Analysen nur begrenzte Möglichkeiten, da die Daten auf wenige extrahierte Merkmale beschränkt sind, z.B. Alter der Fahrerin, Datum, Tageszeit. Hier kann die Analyse kompletter Texte mit KI-Sprachtechnologie helfen. Ziel dieser Projektidee ist also ein umfassendes Analysesystem, z.B. für verantwortliche Verkehrsplaner, für das Versicherungswesen, für Rechtsanwälte und andere Nutzergruppen, mit dem eine große Zahl von Berichten auf bisher unbekannte Zusammenhänge analysiert werden können.



DATENQUELLEN

Für die Realisierung von REPORT ANALYSIS ist Zugriff auf die folgenden Datenquellen erforderlich, siehe Abschnitt [Datenverzeichnisse]:

- Polizeiberichte⁷
- Schadensmeldungen an Versicherungen⁷
- Straßennetz



VORGEHEN

Durch Anwendung moderner KI-Sprachtechnologie können die Texte von Berichten semantisch eingeordnet werden. Dies geht über die Erfassung von Wortstatistiken weit hinaus und ermöglicht das Erkennen von ähnlichen Begleitumständen in gleichen semantischen Kategorien trotz unterschiedlicher Formulierungen. Dazu muss eine domänenspezifische Ontologie erstellt werden.

Die eigentliche Analyse erfolgt auf der Basis von semantischen Merkmalen mit Clustering-Verfahren. Bei der erwarteten Vielzahl von Merkmalen für jeden Bericht bieten sich Neuronale Netze (NN) an, mit denen Zusammenhänge in großen Datenbeständen ermittelt werden können.

Für spezifische Zwecke können auch Klassifikatoren entwickelt werden, z.B. für unfallträchtige Orte, Zeiten und Straßenführungen. Hierzu kann im Wesentlichen derselbe technologische Ansatz mit NN gewählt werden.

⁷ Diese Daten sind unserer Kenntnis nach nicht als Open Data verfügbar.



TECHNOLOGIEREIFEGRAD (TRL)

TRL 3: Nachweis der Funktionstüchtigkeit einer Technologie (5-13 Jahre)



WEITERE ANWENDUNGSMÖGLICHKEITEN

Die Analyse von textuellen Berichten im Hinblick auf interessante Zusammenhänge kann viele weitere Anwendungen finden, von denen einige auch bereits realisiert sind, z.B. die Analyse von Geschäftsberichten als Basis für Börsenentscheidungen. Für jede Anwendungsdomäne ist jeweils ein dedizierter ontologischer Rahmen zu entwickeln.

6. ERFAHRUNGEN UND AUSBLICK

6.1. NUTZEN VON KI-VERFAHREN

Die Untersuchungen im Rahmen des Projektes haben zahlreiche Einsichten in die Nutzungsmöglichkeiten von KI für innovative Open Data-Anwendungen ergeben. Die wichtigsten Aspekte sind im Folgenden zusammengestellt.

- Eine Vielzahl von Datenquellen steht grundsätzlich zur Verfügung, leider noch nicht alle wünschenswerten Open Data (z.B. Daten über Personenbewegungen).
- KI-Methoden sind als Software-Werkzeuge realisiert und verfügbar. Beispiele für Werkzeuge werden in Abschnitt 3.8 aufgeführt
- KI unterstützt Integration von heterogenen Datenquellen, z.B. ÖPNV-Fahrpläne, Schadstoffquellen, Ereignisse, Wetter, Wochentage, Jahreszeiten.
- KI bietet Mustererkennung und Klassifikation von komplexen Daten, z.B. Erkennung von Schadstoffgefährdung ohne Messstellen.
- KI ermöglicht Vorhersagen aufgrund von gespeicherten Erfahrungen, z.B. Schadstoffgefährdung bei der Stadtplanung
- KI ermöglicht vorhersehende Wartung mit gelernten Mustern und Daten aus dem Internet-of-Things
- KI bietet komplexe Szeneninterpretation zur Erkennung von Verkehrsstörungen oder zur Vorausschau von Verkehrsverhalten beim autonomen Fahren
- Viele KI-Werkzeuge bieten anschauliche Visualisierungsmöglichkeiten

Insgesamt ist also zu erwarten, dass die Anwendung von KI-Methoden auf Daten im Mobilitätsbereich deutlichen Nutzen für Bürger und Wirtschaft bietet.

6.2. HERAUSFORDERUNGEN BEI DER ANWENDUNG VON DEEP LEARNING

Eine KI-Methode, von der man sich zurzeit besonders viele Vorteile verspricht, ist das Deep Learning (s. Abschnitt 3.3.2). Die folgenden Anmerkungen sollen auf Aspekte aufmerksam machen, die dabei zu beachten sind und im Vergleich zu anderen Lernverfahren größere Herausforderungen darstellen.

- Deep Learning ist datenhungrig und braucht eine große Menge von Trainingsdaten
- Open Data für Deep Learning müssen kontinuierlich gesammelt werden, um interessante Anwendungen zu unterstützen
- Große gelernte NN sind undurchsichtig. Die Vielzahl ihrer Parameter kann nicht interpretiert werden. NN bieten also keine Erklärungen für Resultate. Diese sind aber in vielen Fällen zur Begründung von Entscheidungen erforderlich.
- NN sind oberflächlich: Sie verwenden meist kein semantisch strukturiertes Wissen.
- NN sind domänenspezifisch, ein Transfer in erweiterte oder andere Anwendungsdomänen ist problematisch.

Für umfassende Aufgaben (z.B. Planungssysteme, vorausschauendes Fahren) sind hybride Ansätze erforderlich, die Mustererkennung mit logikbasierten Verfahren und Reasoning verbinden.

6.3. EMPFEHLUNGEN ZUR DURCHFÜHRUNG VON KI-PROJEKTEN

Ein KI-Projekt besteht in der Regel aus mehreren Teilaufgaben, die unterschiedliche Anforderungen stellen.

MODELLIERUNG DES PROBLEMS

Ein erster wichtiger Schritt ist das Problemverständnis auf einer hohen konzeptuellen Ebene, z.B. in Gestalt von Informationen (nicht Daten!), die als Eingangsdaten zur Verfügung stehen und in den Ausgangsdaten gewonnen werden sollen. Diese Ebene wird in der KI traditionell "Wissensebene" genannt.

AKQUISITION VON DATEN

Wie die Anmerkungen zu einigen Projektskizzen zeigen, sind die erforderlichen oder wünschenswerten Daten nicht immer als Open Data zugänglich. Hier sind Verhandlungen und Überzeugungskraft erforderlich.

DATENAUFBEREITUNG

Bevor Daten in einem KI-Verfahren, insbesondere für Deep Learning, eingesetzt werden können, müssen sie meist in Vorschau auf das Verfahren bearbeitet werden. Dazu gehört z.B. eine Reduzierung von Wertebereichen auf eine angemessene Differenzierung (genügend feinkörnig für den Zweck, aber nicht mehr Werte als nötig).

AUSWAHL UND PARAMETRIERUNG VON KI-VERFAHREN

Die Beschreibung von KI-Verfahren in Abschnitt 3 weist an mehreren Stellen auf alternative Methoden für gleiche Zwecke hin. Hier sind detaillierte Auswahlkriterien heranzuziehen, die ohne vertiefte KI-Kenntnisse in der Regel nicht zur Verfügung stehen. Darüber hinaus bieten KI-Verfahren häufig zahlreiche Möglichkeiten zur Konfigurierung, z.B. durch Angabe einer gewünschten Zahl von Schichten in einem NN. Auch hier ist Expertise erforderlich.

EXPERIMENTIERPHASE

Wegen der manchmal nicht überblickbaren Datenmengen und unbekannter Zusammenhänge, aber auch fehlenden Erfahrungen mit KI-Werkzeugen, muss eine Experimentierphase eingeplant werden. Diese kann zeitaufwändig sein, insbesondere bei der Verwendung von Deep Learning.

INTEGRATION IN EIN VORHANDENES IT-SYSTEM

Die Anwendung einer KI-Methode ist häufig nur eine Komponente im Gesamtsystem, deshalb muss Integrationsarbeit eingeplant werden. Andere Komponenten könnten z.B. Visualisierungsverfahren mit Benutzerinteraktion sein.

6.4. VERTEILTE ROLLEN IN KI-PROJEKTEN

An der Durchführung von KI-Projekten müssen verschiedene Personengruppen mit jeweils eigenen Rollen, aber als zusammenarbeitendes Team, beteiligt werden.

ANWENDERINNEN

Der Ausgangspunkt eines jeden Software-Projektes, so auch von KI-Projekten, ist die Ermittlung von Anforderungen seitens der NutzerInnen, also z.B. von BürgerInnen, Fahrgästen, VerkehrsteilnehmerInnen.

DOMÄNENEXPERTINNEN

Für ein tieferes Verständnis der betroffenen Domäne müssen Fachleute hinzugezogen werden, z.B. ExpertInnen für Verkehrsplanung, Schadstoffausbreitung oder Stadtplanung.

KI-EXPERTINNEN

Die Modellierung von Anwendungsaufgaben zur Verarbeitung mit KI-Methoden und die effektive Anwendung von KI-Methoden erfordern KI-Fachwissen. Dazu gehören z.B. Kenntnisse über den Aufbau von Ontologien oder die Verwendung von Clustering-Verfahren mit NN.

SOFTWARE-HAUS

Die gebrauchsfertige Realisierung eines KI-Systems sollte in Zusammenarbeit mit einem professionellen Software-Haus erfolgen. Diese verfügen in der Regel über die erforderlichen Erfahrungen bei der Integration mit existierender Software, der Gestaltung von Benutzungsschnittstellen und anderen klassischen IT-Aufgaben.

Im Projekt ODAKI fanden Anwendungsentwicklungen nur für die Erstellung von Demonstratoren statt. Die Interviewpartner in ODAKI fungierten dabei als DomänenexpertInnen. Das Projekt-Team von HITeC war vorwiegend in der Rolle von KI-ExpertInnen tätig.

6.5. ABSCHLUSS-WORKSHOP

Am 23.03.2018 veranstaltete HITEC einen Abschluss-Workshop, zu dem Stakeholder, Projektbeteiligte, mFund-Begleitforschung, mFund-Förderer und potenzielle zukünftige Projektpartner eingeladen waren. Den Teilnehmern wurden die Ergebnisse des Projektes ODAKI vorgestellt, im Anschluss fand eine lebhafte Diskussion statt. Die Ideenskizzen sind auf reges Interesse gestoßen, Interessenten an der Weiterführung von Ideenskizzen haben sich gemeldet.

Die Präsentationsfolien zum Abschluss-Workshop sind auf der Projekt-Webpage abrufbar, siehe <http://odaki.informatik.uni-hamburg.de/abschluss-workshop/>.

7. QUELLENANGABEN

7.1. DATENVERZEICHNISSE

Die hier kurz vorgestellten Datenquellen⁸ haben einen starken Hamburg-Bezug. Vergleichbare Datensätze sind auch oft von anderen Städten zu finden. Eine Suche im deutschlandweiten oder europäischen Open Data Portal ist empfehlenswert, da dort oft stadtspezifische Portale subsumiert sind.

Hier ist eine Auswahl an städtischen und länderspezifischen Open Data Portalen:

<https://mcloud.de>

<https://govdata.de>

<https://transparenz.hamburg.de>

<https://europeandataportal.eu>

<https://geoseaportal.de>

<https://data.deutschebahn.com>

Stadtplan und Straßennetz

Das Hamburger Straßennetz kann über einen Web Feature Service der Geodienste Hamburg abgefragt werden.

https://geodienste.hamburg.de/HH_WFS_Hauptverkehrsstrassen

Über eine Open Street Map (OSM) API können Map-Daten lizenzkostenfrei eingesetzt und beliebig weiterverarbeitet werden. Jedoch ist die Abfrage ohne Registrierung beschränkt.

<http://openstreetmap.org>

Fuß- oder Radwege sind über spezielle Parameter in der OSM abrufbar.

Spezielle Ziele in der Umgebung können bei Kartenanbietern wie Google über die API und besondere Parameter („places“) abgerufen werden.

<https://developers.google.com/places/>

Bike Sharing-Daten

Die Daten des Bikesharing-Anbieters „Stadtrad“ (Deutsche Bahn) aus Hamburg werden z.B. im Open Data Portal von der Deutschen Bahn, GovData oder der mCloud zur Verfügung gestellt. Es sind die Standorte und die im Moment zur Verfügung stehenden Räder abrufbar, sowie die Buchungen (Checkout-/Checkin-Daten).

https://developer.deutschebahn.com/store/apis/info?name=Flinkster_API_NG&version=v1&provider=DBOpenData#!

<http://data.deutschebahn.com/dataset/data-call-a-bike>

Car Sharing-Daten

⁸ Stand 31.März 2018

Der Car Sharing-Anbieter Car2Go oder die Deutsche Bahn Tochter Flinkster bietet unter der folgenden APIs die Informationen ihrer Flotte zum zur Weiterverwendung an.

<https://www.car2go.com/api/tou.htm>

<http://data.deutschebahn.com/dataset/data-flinkster>

Verkehrsdichte Straßenverkehr

Für das Hamburger Stadtgebiet werden Zahlen über die Verkehrsdichte an repräsentativen Zählstellen auf Hauptverkehrsdaten ab 2014 erhoben. Für Verkehrsprognosen sind diese Verkehrsmengenangaben laut Bereitsteller nicht geeignet.

http://datenhamburg.de/transport_verkehr/verkehrsmengen_hauptverkehrsstrassen/Verkehrsmengen_Hauptverkehrsstrassen_HH_2016-10-24.zip

An repräsentativen Zählstellen werden auch Fußgänger, Kfz- und Radverkehrszahlen in der Stadt erfasst:

<https://www.govdata.de/web/guest/suchen/-/details/verkehrszahlstellen-hamburg1>

Dynamische Verkehrsdaten können kostenpflichtig bei diesen Herstellern bezogen werden:

<https://help.here.com/de/ios/maps>

https://www.tomtom.com/en_gb/trafficindex

Bewegungsdaten/Personenströme

Um anonymisierte und aggregierte Bewegungsdaten von Personen zu analysieren, können die Mobilfunkdaten von Fahrgästen genutzt werden. Diese sind z.B. vom Anbieter Telefonica AG als Paid-Service verfügbar. Ein Beispielmonat wurde von Telefonica im Rahmen des 3. BMVI Data-Runs zur Verfügung gestellt, diese sind aber nicht als Open Data zugreifbar.

Zudem können örtlich begrenzte Bewegungsdaten aus der Nutzung eines WLANs extrahiert werden. Dies muss aber selbst implementiert werden.

FUNKZELLENINFORMATIONEN

Funkzelleninformationen sind aus vereinzelt Regionen als Open Data veröffentlicht, wie die Standorte der Mobilfunkantennen aus der Hansestadt Rostock.

<https://www.govdata.de/web/guest/suchen/-/details/mobilfunkantennen-hro>

Video - Verkehrsdaten

Verkehrskamerabilder der Verkehrsleitzentrale Hamburg sind über das Internet zugreifbar.

<http://www.hamburg.de/verkehrskameras/>

<https://www.govdata.de/web/guest/suchen/-/details/verkehrskameras-hamburg7>

Der Datensatz enthält eine Auswahl von Verkehrskameras aus dem Hamburger Stadtgebiet, deren Standorte und die dazugehörigen Kamerabildern Livestream. (Aus Datenschutzgründen kann es zu Unterbrechungen des Streams kommen.)

ÖPNV/-FV-Daten

HVV-FAHRPLAN

Im Hamburger Verkehrsverbund ist es möglich über eine API abzurufen, für die man sich registrieren muss, siehe

<http://www.hvv.de/fahrplaene/abruf-fahrplaninfos/uebersicht/index.php>

HVV-HALTESTELLENINFORMATIONEN

Informationen über die Einzugsbereiche von HVV-Haltestellen sind auffindbar unter

<http://suche.transparenz.hamburg.de/dataset/einzugsbereiche-von-hvv-haltestellen3>

Haltestellennamen mit Georeferenzen sind auffindbar hier

<http://suche.transparenz.hamburg.de/dataset/hvv-haltestellennamen-mit-koordinate-hamburg>

Generell sind die Soll-Fahrpläne zugänglich, nicht aber die Ist-Zeiten.

HVV-BENUTZUNG

Ein Datensatz über die Passagierzählung in der Hamburger S-Bahn ist im Open Data Portal der Deutschen Bahn zu finden. Es handelt sich um unbereinigte Rohdaten, die umgerechnet werden, um zu einem Gesamtbild zu kommen. Im Netz der S-Bahn fahren einzelne Zählfahrzeuge täglich im Netz mit und erheben die Fahrten.

<https://data.deutschebahn.com/dataset/passagierzahlung-s-bahn-hamburg>

ÖPFV-DATEN

Haltestellen-, Bahnhofs-, Streckennetz-, Tunnelinformationen des Fernverkehrs der Deutschen Bahn sind im firmeneigenen Open Data-Portal zu finden

<https://data.deutschebahn.com>

Parkraumdaten

Informationen zu Parkplätzen, z.B. zu Reisebusparkplätzen, Park & Ride-Anlagen, Parkhausinformationen (zum Teil mit Belegungsinformationen), Motorrad-, oder Behindertenstellplätzen sind im

https://www.europeandataportal.eu/data/de/dataset?country=de&ext_geo_input=&q=Parkplatz

zu finden.

Baustellenplanung

Baustelleninformationen werden in regelmäßigen Abständen veröffentlicht, in Hamburg durch den Landesbetrieb für Straßen, Brücken und Gewässer, diese sind über GovData bzw. das Transparenzportal der Stadt über einen Web Feature Service abrufbar.

<https://www.govdata.de/web/guest/suchen/-/details/baustellen-auf-hauptverkehrs-und-bundesfernstrassen-hamburg>

3D-Stadtmodell

Das 3D-Stadtmodell von Hamburg ist in zwei unterschiedlichen Detaillierungsgraden frei abrufbar.

<https://www.govdata.de/web/guest/daten/-/details/3d-stadtmodell-hamburg1>

Andere Stadtmodelle sind bis dato z.B. von der Stadt Köln oder Berlin verfügbar.

Bebauungspläne

Bebauungspläne werden als Open Data veröffentlicht, liegen dann jedoch als pdf vor.

<https://www.europeandataportal.eu/data/de/dataset?q=Bebauungsplan>

Bewohnerstatistiken

Die Statistikämter veröffentlichen umfangreiche Informationen zu den Bewohnern und ihren Lebensumständen, etwa der Altersaufteilung, Anteil Leistungsempfänger, Anzahl Kinder, Anzahl PKW, Wohnungsgrößen, Anzahl Ärzte, Kindergärten etc.

<https://www.statistik-nord.de/zahlen-fakten/regionalstatistik-datenbanken-und-karten/hamburger-stadtteil-profile-und-interaktive-karten/>

Kriminalitätsstatistiken

Kriminalitätsstatistiken, bereitgestellt vom Bundeskriminalamt für die Jahre 2012-2016 im pdf-Format.

https://www.bka.de/DE/AktuelleInformationen/StatistikenLagebilder/PolizeilicheKriminalstatistik/pks_node.html

Kriminalitätsstatistiken im CSV-Dateien sind über das GovData-Portal abrufbar.

Luftqualitätsdaten

Hamburgs offizielle Messstellen, betrieben vom Bundesamt für Umwelt und Energie, veröffentlichen hier die Messergebnisse ihrer Stationen:

<http://luft.hamburg.de>

Die Daten der Deutschlandweiten Initiative zur Erhebung von Feinstaubdaten durch Crowd-Sourcing (Selbstbau von Feinstaubmessgeräten) sind unter

<https://luftdaten.info>

oder über die Schnittstelle

<http://api.luftdaten.info/v1/>

abrufbar.

Das Start-up Breeze hat einen kostengünstigen Sensor für die Messung der Luftqualität entwickelt, zudem bietet es eine Analyse-Katalog mit Maßnahmen zur Verbesserung der Luftqualität.

<https://www.breeze-technologies.de/de/loesungen/luftqualitaetsmonitoring-fuer-staedte/>

In Hamburg und Berlin hängen bereits einige Sensoren.

Wetterdaten

Die Wetterdaten, wie Windrichtung, Windstärken, Temperatur, Luftdruck werden vom Deutsche Wetter Dienst (DWD) historisch oder tagesaktuell über den Webservice des DWD bereitgestellt.

<https://www.dwd.de/DE/leistungen/geowebsevice/geowebsevice.html?nn=508722>

Pegelstände

Pegelstände von Binnen- und Küstengewässern können über einen Web Feature Service abgerufen werden. Historische Daten müssen speziell angefordert werden, sind aber verfügbar.

<https://www.pegelonline.wsv.de/gast/start>

Historische Fotos - eFoto Hamburg

Die Hamburger Kulturbehörde wird 2018 im Projekt eFoto ein digitales Bildarchiv der Stadt veröffentlichen, in dem historische Fotos mit Kontextinformationen und Geo-Referenzierungen über eine API frei zur Verfügung stehen.

<http://efoto-hamburg.de>

Veranstaltungsdaten Hamburg

Für den Hamburger Großraum werden durch die Hamburg Tourismus GmbH Veranstaltungsdaten geo-referenziert, maschinenlesbar jedoch kostenpflichtig zur Verfügung gestellt.

<http://www.hamburg-tourism.de/>

Geo-Tools

OSGeo-Live ist eine Virtuelle Maschine basierend auf Ubuntu, die eine Vielzahl von Geo-Software anbietet:

https://live.osgeo.org/en/quickstart/virtualization_quickstart.html

<http://docs.geotools.org>

<http://bimserver.org/>

Hilfe bei der Umrechnung und Darstellung von Geo-Koordinaten

<https://www.sunearthtools.com/de/tools/distance.php>

<http://www.movable-type.co.uk/scripts/latlong.html>

<https://codepen.io/jhawes/pen/ujdgK?editors=0011#0>

<https://www.darrinward.com/lat-long/>

7.2. LITERATURVERZEICHNIS

[Baader et al. 2010]

Franz Baader, Diego Calvanese, Deborah I. McGuinness, Daniele Nardi, Peter F. Patel-Schneider, The Description Logic Handbook: Theory, Implementation, and Applications. Cambridge University Press, 2nd edition, 2010

[BDS 2017]

Konferenzprogramm unter <http://2017.bigdatasummit.co>

[Bellahsene et al. 2011]

Zohra Bellahsene, Angela Bonifati, Erhard Rahm (Hrsg.): Schema Matching and Mapping, Springer, 2011.

[Bohlken et al. 2013]

Wilfried Bohlken, Patrick Koopmann, Lothar Hotz, Bernd Neumann: Towards Ontology-Based Realtime Behaviour Interpretation. In H.W. Guesgen, S. Marsland (Hrsg.): Human Behavior Recognition Technologies: Intelligent Applications for Monitoring and Security, IGI Global, 2013, 33-64

[Dong et al. 2008]

Hai Dong, Farookh Khadeer Hussain, Elizabeth Chang: A survey in semantic search technologies. 2nd IEEE International Conference on Digital Ecosystems and Technologies, 2008.

[Dunteman 1989]

George Henry Dunteman: Principal Component Analysis. Sage Publications, 1989

[Edelkamp und Schroedl 2011]

Stefan Edelkamp, Stefan Schroedl: Heuristic Search - Theory and Applications. Elsevier, 2011

[Goodfellow et al. 2016]

Ian Goodfellow, Yoshua Bengio, Aaron Courville: Deep Learning. The MIT Press, 2016

[Harmelen et al. 2008]

Frank van Harmelen, Vladimir Lifschitz, Bruce Porter (Hrsg.): Handbook of Knowledge Representation. Elsevier, 2008

[Hitzler et al. 2010]

Pascal Hitzler, Markus Krötzsch, Sebastian Rudolph, York Sure: Semantic Web. Springer, 2010.

[Hotz et al. 2008]

Haringer, Matthias; Hotz, Lothar; Kamp, Vera: Two Stage Knowledge Discovery for Spatio-temporal Radioemission Data. Proceedings of 5th Prestigious Applications of Intelligent Systems (PAIS08), Patras, 2008, 673-677

[IJCAI-2017]

26th International Joint Conference on Artificial Intelligence, 19-25 August, Melbourne. Proceedings unter <https://www.ijcai.org/proceedings/2017/>

[Kolodner 1993]

Janet Kolodner: Case-Based Reasoning. Morgan Kaufmann, 1993

[Mikolov et al. 2013]

Tomas Mikolov, Kai Chen, Greg Corrado, Jeffrey Dean: Efficient Estimation of Word Representations in Vector Space. arXiv:1301.3781 [cs.CL], 2013

[Minsky 1968]

Marvin Minsky (Hrsg.): Semantic Information Processing. The MIT Press, 1968

[OWL 2011]

OWL 2 Document Overview (Second Edition), 2011

<http://www.w3.org/TR/owl2-overview/>

[Pearl et al. 2016]

Judea Pearl, Madelyn Glymour, Nicholas P. Jewell: Causal Inference in Statistics. Wiley, 2016

[Rana et al. 2017]

Anup Kumar Rana, David Sorejevic, Elizaveta Konyahina, Henri Engelhardt, Isabella Tran, Maria Baykova, Na_seh Zadehnour, Nikolai Elich, Stepan Chakhar, Svetlana Fukalova, Tim Pietz Vitaliy Vaneev: Entwicklung der Histoury-APP im Rahmen eines MLAB-Projektes des Fachbereichs Informatik an der Universität Hamburg im Auftrag von HITeC e.V., <https://mast.informatik.uni-hamburg.de/mlab/>, 2017.

[Ricci et al. 2011]

Francesco Ricci, Lior Rokach, Bracha Shapira, Hrsg.: Recommender Systems Handbook. Springer, 2011

[Russell & Norvig 2010]

Stuart Russell, Peter Norvig: Artificial Intelligence - A Modern Approach. Pearson, 2010

7.3. KI-BIBLIOTHEKEN

Die im Rahmen des Projektes recherchierten KI-Bibliotheken im Rahmen der Arbeit an den Demonstratoren und bei den Hackathons werden im Folgenden aufgeführt.

APIs und SW-Bibliotheken

Apache MXNet - Open Source Bibliothek für Deep Learning
<https://mxnet.io>

ResNet-50 - 50 Layer/Schichten Residual Network
(Varianten ResNet101, -152 verfügbar)
<https://github.com/KaimingHe/deep-residual-networks>

Keras – Neural Network Bibliothek in Python
<https://keras.io/>

LeNet - Convolutional Neural Network Bibliothek in Python
<http://yann.lecun.com/exdb/lenet/>

Gluon - API für Deep Learning, Machine-Learning Bibliothek von AWS & Microsoft
<https://github.com/gluon-api/>

Kaggle – Plattform für Vorhersage und Analyse-Wettbewerbe
<https://www.kaggle.com>
<https://www.kaggle.com/datasets>

Pandas – Open-Source Bibliothek in Python zur Datenanalyse
<https://pandas.pydata.org>

Caret – R-Paket zum Entwurf von Klassifikationen und Regressionsmodellen,
bietet Tools zur Datenaufbereitung, -Splitting und Modelauswertung
<http://caret.r-forge.r-project.org>

pROC – R-Paket zur Visualisierung und Glättung von ROC-Kurven
<https://cran.r-project.org/package=pROC>

ggplot2 – R-Paket zur Datenvisualisierung
<http://ggplot2.org>

ggmaps – Funktionssammlung in R zur Visualisierung von räumlichen Daten
und Modellen auf statischen Karten
(unterschiedlicher Anbieter etwa Google oder Stamen)
<https://cran.r-project.org/package=ggmap>

vtreat – R-Paket zur Datenvorverarbeitung
<https://cran.r-project.org/package=vtreat>

scikit-learn – Python-Paket für Machine Learning in Python
<http://scikit-learn.org>

Beispieldatensätze zum Trainieren

MNIST – Großer Datensatz von handgeschriebenen Zahlen
<http://yann.lecun.com/exdb/mnist/>

CIFAR-10 – Datensatz aus 80 Mio. kleinen gelabelten Farbbildern
<https://www.cs.toronto.edu/~kriz/cifar.html>

Imagenet - Bild-Datenbank nach Wordnet
<http://www.image-net.org>

Machine Learning-Entwicklungsumgebungen

Jupyter - Entwicklungsumgebung
<http://jupyter.org>

Anaconda - Entwicklungsumgebung für Python und R zum Paketmanagement und Softwareverteilung
<https://anaconda.org>

Neptune – ML-Entwicklungsumgebung in der Cloud
<https://neptune.ml>

Gesichtserkennung

Microsoft Faces
<https://azure.microsoft.com/de-de/services/cognitive-services/face/>

Maschinelles Übersetzen

Sockeye (Machine translation, sequence-to-sequence models)
<https://aws.amazon.com/de/blogs/ai/train-neural-machine-translation-models-with-sockeye/>
<https://github.com/aws-labs/sockeye>

Machine Translation Beispiel (translation of news headlines): Mithilfe eines LSTM (Long Short-Term Memory Networks), Sockeye + MXNet

Verkehrssimulation

SUMO – Verkehrssimulationsanwendung des DLR
http://www.dlr.de/ts/en/desktopdefault.aspx/tabid-9883/16931_read-41000/

Vortrainierte Neuronale Netze

Übersicht über Veröffentlichungen zu vortrainierten Neuronen:
<https://github.com/GalacticExchange/pretrained>

Fahrzeugdetektion mit vortrainierten Gewichten für ein Neuronales Netz:
<https://github.com/subodh-malgonde/vehicle-detection>